



TESIS - SS142501

**PENGARUH FAKTOR CUACA TERHADAP
PERAMALAN INFLASI BAHAN MAKANAN DI
PULAU PAPUA DENGAN MODEL GSTARX**

HARNIATY
NRP. 1315201703

DOSEN PEMBIMBING

Dr. Brodjol Sutijo S.U, M.Si
Dr. Suhartono, M.Sc

**PROGRAM MAGISTER
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017**



THESIS - SS142501

THE IMPACT OF WHEATER RISK ON FORECASTING INFLATION OF VOLATILITY FOODS IN PAPUA USING GSTARX MODEL

HARNIATY
NRP. 1315201703

SUPERVISORS

Dr. Brodjol Sutijo S.U, M.Si
Dr. Suhartono, M.Sc

**MAGISTER PROGRAM
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOVENBER
SURABAYA
2017**

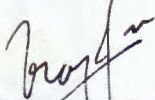
PENGARUH FAKTOR CUACA TERHADAP PERAMALAN INFLASI BAHAN MAKANAN DI PULAU PAPUA DENGAN MODEL GSTARX

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh:

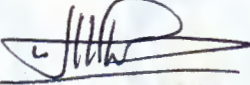
HARNIATY
NRP. 1315 201 7103

Tanggal Ujian : 6 Januari 2017
Periode Wisuda : Maret 2017

Disetujui oleh:


1. Dr. Brodjol Sutijo S.U. M.Si
NIP. 19660125 199002 1 001

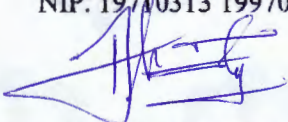
(Pembimbing I)


2. Dr. Suhartono, M.Sc
NIP. 19710929 199512 1 001

(Pembimbing II)


3. Dr. Sutikno, M.Si
NIP. 19710313 199702 1 001


(Penguji)


4. Dr. rer.pol. Dedy Dwi Prastyo, M.Si
NIP. 19831204 200812 1 002

(Penguji)


5. Dr. Titi Kanti Lestari, SE. M.Com
NIP. 19611231 198312 2 001

(Penguji)



Direktur Program Pasca Sarjana,

Prof. Ir. Djauhar Manfaat, M.Sc., Ph.D.
NIP. 19601202 198701 1 001

PENGARUH FAKTOR CUACA TERHADAP PERAMALAN INFLASI BAHAN MAKANAN DI PULAU PAPUA DENGAN MODEL GSTARX

Nama Mahasiswa : Harniaty
NRP : 1315201703
Pembimbing : Dr. Brodjol Sutijo S.U, M.Si
Co-Pembimbing : Dr. Suhartono, M.Sc

ABSTRAK

Inflasi Bahan Makanan di Pulau Papua sangat fluktuatif karena berhubungan dengan proses distribusi komoditas pangan. Transportasi laut menjadi moda utama dalam mendistribusikan komoditas pangan antar wilayah. Peramalan Inflasi Bahan Makanan (IBM) di Pulau Papua dengan melibatkan unsur *spatio-temporal* dapat menggunakan model *Generalized Space Time Autoregressive* (GSTAR). Penambahan variabel eksogen berupa faktor cuaca diharapkan mampu meningkatkan akurasi peramalan sehingga pemodelan GSTARX perlu dilakukan. Faktor cuaca yang menjadi fokus dalam penelitian ini adalah tinggi gelombang dan kecepatan angin pada tiga wilayah di pulau Papua, yaitu Kota Jayapura, Manokwari dan Sorong. Penentuan bobot lokasi menjadi hal yang penting dalam estimasi parameter. Oleh karena itu, pada penelitian ini diusulkan bobot konektivitas dan matriks segi tiga atas selain menggunakan beberapa bobot spasial yang terdapat dalam model GSTAR. Pemilihan model terbaik dalam meramal data IBM tidak hanya terbatas pada model GSTAR/GSTARX. Namun, sebagai keterbandingan akan dilakukan peramalan IBM menggunakan model ARIMA, Fungsi Transfer dan GSTAR. Berdasarkan perbandingan nilai RMSE terkecil, hasil kajian peramalan IBM menunjukkan bahwa model GSTARX-GLS $([1,2]_1)$ dengan bobot normalisasi korelasi silang baik dalam meramal data IBM di Kota Sorong dan Manokwari. Sedangkan pemodelan Fungsi Transfer baik dalam meramal IBM di Kota Jayapura. Bobot matriks segi tiga atas pada model GSTAR memberikan hasil peramalan yang lebih baik jika tanpa melibatkan variabel eksogen. Akan tetapi, penggunaan bobot konektivitas dalam model GSTAR tidak memberikan hasil peramalan yang lebih baik dibanding bobot spasial lainnya, dengan atau tanpa menggunakan variabel eksogen.

Kata kunci: GSTARX, Matriks segi tiga atas, Inflasi bahan makanan, Papua

THE IMPACT OF WHEATER RISK ON FORECASTING INFLATION OF VOLATILITY FOODS IN PAPUA USING GSTARX MODEL

Name : Harniaty
NRP : 1315201703
Supervisor : Dr. Brodjol Sutijo S.U, M.Si
Co-Supervisor : Dr. Suhartono, M.Sc

ABSTRACT

The volatility of the inflation foodstuffs in Papua is related to the distribution of food commodities. The freight ship becomes the main modes of distributing food commodities between regions, such as Jayapura, Manokwari and Sorong. Forecasting of inflation foodstuffs (IBM) in Papua which involve spatio-temporal effect, can be used Generalized Space Time Autoregressive (GSTAR) model. The weather marine, such as the wave height and wind speed, affixed to GSTAR model on purpose enhancing accuracy of forecasting. The spatial weight is the important part of estimation parameters. Therefore, in this study we purpose connectivity matrices and upper triangular matrices as an alternative besides on spatial weight matrices often use in GSTAR model. Selection of the best models on forecasting IBM's data not only limited to GSTAR / GSTARX but also on ARIMA models and Transfer Function. The smallest value of RMSE will be compared as the best model to forecasting IBM's data. The GSTARX-GLS ([1,2]₁) model with cross-correlation normalization matrices give the best forecast accuracy than other model in Sorong and Manokwari. Whereas Transfer Function model give the best forecast in Jayapura. Triangular matrices as spasial matrices in GSTAR provide better forecasting result without involving exogenous variabel in model. However, connectivity as spatial matrices in GSTAR is not giving a better forecasting than other spatial matrices, with or without exogenous variable

Key words: GSTARX, Upper Triangular Matrices, Inflation of foods.

KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah SWT yang telah melimpahkan karunia dan rahmat kepada penulis sehingga tesis yang berjudul “Pengaruh Faktor Cuaca Terhadap Peramalan Inflasi Bahan Makanan di Pulau Papua dengan Model GSTARX” ini dapat diselesaikan sesuai dengan waktu yang diharapkan. Tesis ini disusun dalam rangka memenuhi salah satu syarat untuk meraih gelar Magister Sains di Program Pascasarjana Statistika Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih dan penghargaan yang setinggi-tingginya kepada :

1. Badan Pusat Statistik (BPS) yang telah memberikan kesempatan, dukungan dan beasiswa kepada penulis untuk melanjutkan studi program S2 di ITS.
2. Bapak Dr. Brodjol Sutijo S.U, M.Si dan Dr. Suhartono, M.Sc selaku dosen pembimbing yang ditengah segala kesibukannya dapat meluangkan waktu untuk memberikan bimbingan, saran, masukan serta motivasi selama penyusunan tesis ini
3. Bapak Dr. Sutikno, M.Si, Bapak Dr.rer.pol. Dedy Dwi Prastyo, M.Si dan Ibu Dr. Titi Kanti Lestari, SE, M.Com selaku dosen penguji yang telah memberikan arahan dan koreksi atas penulisan tesis ini.
4. Bapak Dr.rer.pol. Heri Kuswanto, M.Si selaku Kaprodi Pascasarjana Statistika ITS sekaligus dosen pembimbing akademik atas segala arahan dan bimbingan yang telah diberikan selama proses studi.
5. Bapak Ibu dosen Statistika ITS yang telah memberikan ilmu dan pengalamannya selama proses studi. Seluruh jajaran staf jurusan Statistika ITS atas segala bantuan dan fasilitas yang diberikan.
6. Suamiku tercinta, Anton Ari Widodo, terima kasih atas segala kasih sayang, kesabaran, doa, dan pengertian yang luar biasa diberikan kepada penulis sehingga penulis mampu menyelesaikan masa studi tepat waktu.
7. Anakku tersayang, Muh. Faiz Rafasya dan Naufal Danish Azzahidi, terima kasih atas semangat dan doa yang kalian berikan. Doa dan harapan terbaik

buat duo jagoan kecilku. Mama meminta maaf atas waktu 1,5 tahun ini yang terenggut dari kalian.

8. Mama Rasni, Kakek Sunudi, Bapak Slamet dan Ibu Hartati atas segala doa, perhatian dan bantuannya selama ini. Mohon maaf, penulis selalu merepotkan. Semoga Allah SWT selalu memberikan rahmat dan kasih sayangnya – Nya kepada orang terkasihku ini.
9. Buat Adik-adikku Risna, Ika, Afri dan Nurul, terimakasih dik atas segala bantuannya momong anak-anakku. Buat Bude Uggie dan Mbah Nyemik, ibu kedua dari danish, terima kasih sudah mau direpoti.
10. Teman seperjuangan *Time Series*, Mas Agung dan Mbak Risma, terima kasih yang sebesar-besarnya atas segala bantuan dan pertemanan yang menyenangkan ini. Mohon maaf karena selalu merepotkan kepada beliau berdua.
11. Mbak-mbak terkasihku, Mbak Risma, Mbak Nunik, Mbak Ervin, Mbak Mety, Mbak Lila dan Irva. Meskipun tidak bertalian darah, mbak sekalian adalah saudaraku. Alhamdulillah, bersyukur dapat mengenal mbak sekalian.
12. Mbak Ika, Mbak Ayu, Tiara dan mbak mas angkatan Batch 9 BPS yang tidak dapat disebutkan satu persatu. Penulis mengucapkan banyak terima kasih atas bantuan, kebersamaan dan kekompakan selama ini.
13. Semua pihak yang telah membantu penyelesaian tesis ini.

Surabaya, Januari 2017

Penulis

DAFTAR ISI

	Halaman
ABSTRAK	iii
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xxiii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	6
1.3 Tujuan Penelitian.....	7
1.4 Manfaat Penelitian.....	7
1.5 Batasan penelitian.....	7
BAB 2 TINJAUAN PUSTAKA.....	9
2.1 Model Time Series.....	9
2.2 Metode ARIMA Box Jenkins	9
2.2.1. Identifikasi Model ARIMA (p,d,q).....	10
2.2.2. <i>Autocorrelation Function</i> (ACF) dan <i>Partial Autocorrelation Function</i> (PACF).....	12
2.2.3. Estimasi dan Uji Signifikansi Parameter	12
2.2.4. Uji Kesesuaian Model	14
2.2.5. Peramalan ARIMA	16
2.3 Deteksi <i>Outlier</i>	17
2.3.1. <i>Additive Outlier</i> (AO).....	17
2.3.2. <i>Innovational Outlier</i> (IO)	18
2.3.3. <i>Level Shift</i> (LS).....	18

2.3.4. <i>Temporary Change</i> (TC)	19
2.4 Model Fungsi Transfer	19
2.5 Model Time Series Multivariat	25
2.5.1. Matrix Cross Correlation Function (MCCF).....	26
2.5.2. Matrix Partial Cross Correlation Function (MPCCF)	27
2.5.3. Akaike's Information Criterion (AIC)	29
2.6 Model Generalized Spaced Time Autoregressive (GSTAR)	29
2.6.1. Identifikasi Model pada Model GSTAR	32
2.6.2. Pemilihan Bobot Lokasi pada Model GSTAR	35
2.7 Estimasi Parameter pada Model GSTAR	41
2.7.1. Metode Estimasi <i>Ordinary Least Square</i> (OLS).....	41
2.7.2. Estimasi Parameter dengan <i>Generalized Least Square</i> (GLS).	43
2.7.3. Regresi dengan Residual Berkorelasi.....	45
2.8 Diagnostic Checking Model.....	47
2.9 Kriteria Pemilihan Model Terbaik	47
2.10 Inflasi.....	47
2.11 Faktor Cuaca.....	51
BAB 3 METODOLOGI PENELITIAN.....	55
3.1 Sumber Data	55
3.2 Variabel Penelitian	56
3.2.1. Variabel Output	56
3.2.2. Variabel Input.....	57
3.3 Tahapan Analisis Data.....	57
3.4 Pemodelan ARIMA	57
3.5 Pemodelan Fungsi Transfer	58
3.6 Pembentukan Model GSTARX.....	61

3.7	Pemilihan Model Terbaik	64
3.8	Struktur Data dalam Penelitian Data Inflasi Bahan Makanan Kota Inflasi di Pulau Papua	65
BAB 4	HASIL DAN PEMBAHASAN	67
4.1	Gambaran Umum Inflasi Bahan Makanan di Pulau Papua	67
4.2	Pemodelan ARIMA pada Inflasi Bahan Makanan Tiga Kota di Pulau Papua	72
4.2.1.	Peramalan ARIMA pada Inflasi Bahan Makanan Kota Jayapura	72
4.2.2.	Peramalan ARIMA pada Inflasi Bahan Makanan Kota Manokwari	75
4.2.3.	Peramalan ARIMA pada Inflasi Bahan Makanan Kota Sorong	79
4.3	Pemodelan Fungsi Transfer Inflasi Bahan Makanan di Pulau Papua	84
4.3.1.	Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Jayapura.	84
4.3.2.	Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Manokwari	93
4.3.3.	Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Sorong.....	101
4.4	Pemodelan GSTAR dengan Data Inflasi Tiga Kota di Pulau Papua	108
4.4.1.	Identifikasi Model GSTAR	109
4.4.2.	Estimasi Parameter Model GSTAR.....	110
4.4.3.	Diagnostic Checking Model GSTAR-GLS (1_1)	125
4.4.4.	Pemilihan Model Terbaik Model GSTAR-GLS (1_1).....	126

4.5	Pemodelan GSTARX untuk Peramalan Inflasi Bahan Makanan di Pulau Papua dengan Variabel Eksogen Data Metrik.	127
4.5.1.	Pemodelan Tahapan Pertama dengan Model Fungsi Transfer.	128
4.5.2.	Identifikasi Model GSTARX	128
4.5.3.	Estimasi Parameter pada Model GSTARX	131
4.5.4.	<i>Diagnostic Checking</i> dan Peramalan dengan Model GSTARX-GLS $([1,2]_1)$	146
4.6	Pemodelan GSTARX	146
4.6.1.	<i>Diagnostic Checking</i> Model GSTARX	147
4.6.2.	Pemilihan Model Terbaik pada Model GSTARX	147
4.7	Perbandingan Hasil Pemodelan ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS $([1,2]_1)$ terhadap IBM di Pulau Papua	150
BAB 5	KESIMPULAN DAN SARAN	155
5.1	Kesimpulan	155
5.2	Saran	156
DAFTAR PUSTAKA	157
LAMPIRAN	163
BIOGRAFI PENULIS	177

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Orde Spasial pada satu dan dua dimensi	33
Gambar 2.2 Contoh Hubungan Tiga Lokasi	35
Gambar 2.3 Hubungan kedekatan antara wilayah <i>origin-destination</i> ...	40
Gambar 2.4 Contoh Matriks Bobot Spasial Konektifitas.....	41
Gambar 3.1 Peta lokasi kota inflasi di Pulau Papua (www.maps.google.com).....	56
Gambar 3.2 Tahapan Pemodelan Inflasi dengan Model ARIMA	59
Gambar 3.3 Tahapan Pemodelan Inflasi dengan Model Fungsi Transfer	60
Gambar 3.4 Tahapan Pemodelan Inflasi dengan model GSTARX.....	63
Gambar 3.5 Tahapan Pemilihan Model Terbaik	64
Gambar 4.1 Box-Plot Inflasi Bahan Makanan (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong	68
Gambar 4.2 Plot Time Series Inflasi Bahan Makanan (a) Kota Jayapura (b) Kota Manokwari(c) Kota Sorong	69
Gambar 4.3 Plot Time Series Kecepatan Angin di Tiga Lokasi di Pulau Papua (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong	70
Gambar 4.4 Plot Time Series Tinggi Gelombang di Tiga Lokasi di Pulau Papua (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong	71
Gambar 4.5 Box-Cox <i>Transformation</i> setelah di tambahkan Konstanta (JYPR).....	73
Gambar 4.6 Plot (a) ACF dan (b) PACF Inflasi Bahan Makanan di Kota Jayapura	73
Gambar 4.7 Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) ARIMA Jayapura.....	75
Gambar 4.8 Plot Box-Cox <i>Transformation</i> setelah di tambahkan Konstanta (MKW)	76

Gambar 4.9	Plot ACF (a) dan PACF (b) Inflasi Bahan Makanan di Kota Manokwari.....	76
Gambar 4.10	Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) ARIMA Manokwari	79
Gambar 4.11	Plot Box-Cox data sebelum ditransformasi (a) dan setelah di transformasi akar (b) Inflasi Bahan Makanan di Sorong .	79
Gambar 4.12	Plot (a) ACF dan (b) PACF Inflasi Bahan Makanan di Kota Sorong.....	80
Gambar 4.13	Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) ARIMA Sorong	83
Gambar 4.14	Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi, (b) Tinggi Gelombang Setelah Transformasi (akar) (c) Kecepatan Angin Sebelum Transformasi (d) Kecepatan Angin Setelah Transformasi (akar)	85
Gambar 4.15	Plot ACF (a) PACF (b) Tinggi Gelombang, Plot ACF (c) PACF (d) Kecepatan Angin dan Plot ACF (e) PACF (f) Kecepatan Angin hasil <i>differencing</i> musiman di Kota Jayapura.....	86
Gambar 4.16	Plot Crosscorrelation antara deret (a) input Tinggi Gelombang, (b) Kecepatan Angin tanpa Differencing Musiman, (c) Kecepatan Angin dengan Differencing Musiman di Kota Jayapura.....	89
Gambar 4.17	Plot (a) ACF dan (b) PACF Residual Hasil Pemodelan Fungsi Transfer Sementara Data Input Kecepatan Angin Kota Jayapura.....	91
Gambar 4.18	Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) Fungsi Transfer Jayapura	93
Gambar 4.19	Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi, (b)Tinggi Gelombang Setelah Transformasi	

	(akar), (c) Kecepatan Angin Sebelum Transformasi (d) Kecepatan Angin Setelah Transformasi (akar).....	94
Gambar 4.20	Plot ACF (a) PACF (b) Tinggi Gelombang, Plot (c) ACF (d) PACF Kecepatan Angin dan Plot (e) ACF (f) PACF Kecepatan Angin hasil <i>differencing</i> musiman di Kota Manokwari.....	95
Gambar 4.21	Plot <i>Crosscorrelation</i> antara (a) deret input Tinggi Gelombang, (b) Kecepatan Angin tanpa <i>Differencing</i> Musiman, (c) Kecepatan Angin dengan <i>Differencing</i> Musiman di Kota Manokwari.....	98
Gambar 4.22	Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) Fungsi Transfer Manokwari	100
Gambar 4.23	Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi (b) Kecepatan Angin Sebelum Transformasi	101
Gambar 4.24	Plot (a) ACF (b) PACF Tinggi Gelombang, Plot (c) ACF (d) PACF Kecepatan Angin dan Plot (e) ACF (f) PACF Kecepatan Angin hasil <i>differencing</i> musiman di Kota Sorong.....	102
Gambar 4.25	Plot <i>Crosscorrelation</i> antara deret input (a) Tinggi Gelombang , (b) Kecepatan Angin tanpa <i>Differencing</i> Musiman, (c) Kecepatan Angin dengan <i>Differencing</i> Musiman di Kota Sorong.....	106
Gambar 4.26	Perbandingan data aktual dan ramalan <i>out-sample</i> (kiri) dan nilai RMSE <i>out-sample</i> untuk <i>k-step</i> (kanan) Fungsi Transfer Sorong	108
Gambar 4.27	Representasi Skema MCCF untuk data Inflasi Bahan Makanan di Tiga Lokasi Pulau Papua	109
Gambar 4.28	Representasi Skema MPCCF untuk data Inflasi Bahan Makanan di Tiga Lokasi Pulau Papua	110
Gambar 4.29	Plot time series residual (<i>ni, t</i>) Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua.....	129

Gambar 4.30 Representasi Skema MCCF untuk (ni, t) Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua.....	129
Gambar 4.31 Representasi Skema MPCCF untuk (ni, t) Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua.....	130
Gambar 4.32 Perbandingan Inflasi Bahan Makanan Aktual dan Hasil Peramalan Pemodelan GSTARX-GLS $([1,2]_1)$ Data <i>Out-sample</i> (a) Jayapura (b) Manokwari dan (c) Sorong	149
Gambar 4.33 Perbandingan Time Series Plot Data IBM Aktual dengan Peramalan Model ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS $([1,2]_1)$ Data <i>Out-sample</i> (a) Jayapura (b) Manokwari dan (c) Sorong	151
Gambar 4.34 Perbandingan RMSE Model ARIMA, Fungsi Transfer, GSTAR dan GSTARX Ramalan IBM di Pulau Papua	153

DAFTAR TABEL

	Halaman
Tabel 2.1 Nilai Transformasi Box Cox	11
Tabel 2.2 Pola Teoritik ACF dan PACF dari Proses Stasioner	12
Tabel 2.3 Contoh nilai MCCF untuk tiga data <i>Time Series</i>	27
Tabel 2.4 Contoh Plot MCCF untuk Tiga Data <i>Time Series</i>	27
Tabel 2.5 Contoh nilai MPCCF untuk Tiga Data <i>Time Series</i>	28
Tabel 2.6 Contoh Plot MPPCF untuk Tiga Data <i>Time Series</i>	28
Tabel 2.7 Contoh Jarak dari Tiga Lokasi	36
Tabel 3.1 Jumlah Moda Transportasi Laut yang Melayani antar Lokasi Kota Inflasi di Papua	55
Tabel 3.2 Jarak Tempuh Kapal dengan Transportasi Laut antar Lokasi di Papua	56
Tabel 3.3 Variabel <i>Output</i> dalam Penelitian	56
Tabel 3.4 Variabel <i>Input</i> dalam Penelitian	57
Tabel 3.5 Struktur Data dalam Penelitian Inflasi Bahan Makanan di Pulau Papua	65
Tabel 4.1 Statistik Deskriptif Data Inflasi di Tiga Lokasi.....	67
Tabel 4.2 Statistik Deskriptif Data Cuaca di Tiga Lokasi di Pulau Papua	72
Tabel 4.3 Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Jayapura	74
Tabel 4.4 Hasil Uji Residual <i>White Noise</i> Model ARIMA pada Data Inflasi Bahan Makanan Kota Jayapura.....	74
Tabel 4.5 Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Manokwari.....	77
Tabel 4.6 Hasil Uji Residual <i>White Noise</i> Model ARIMA pada Data Inflasi Bahan Makanan Kota Jayapura.....	77
Tabel 4.7 Nilai AIC Model Dugaan ARIMA inflasi Bahan Makanan di Jayapura.....	78

Tabel 4.8	Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Sorong	80
Tabel 4.9	Hasil Uji Residual <i>White Noise</i> Model ARIMA pada Data Inflasi Bahan Makanan Kota Sorong	81
Tabel 4.10	Nilai AIC Model Dugaan ARIMA inflasi Bahan Makanan di Sorong	81
Tabel 4.11	Hasil Deteksi Outlier Model ARIMA (0,0,1) pada Inflasi Bahan Makanan Kota Sorong	82
Tabel 4.12	Hasil Estimasi Parameter Model ARIMA (0,0,1) dengan deteksi <i>outlier</i> pada Data Inflasi Bahan Makanan Kota Sorong	82
Tabel 4.13	Hasil Uji Residual <i>White Noise</i> Model ARIMA dengan Deteksi <i>Outlier</i> pada Data Inflasi Bahan Makanan Kota Sorong	83
Tabel 4.14	Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Jayapura...	87
Tabel 4.15	Uji Residual Model ARIMA $([5],0,0)(0,1,1)^{12}$, ARIMA $(1,0,0)$, ARIMA $(1,0,0)(1,1,0)^{12}$	88
Tabel 4.16	Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Jayapura	90
Tabel 4.17	Hasil Uji Residual <i>White Noise</i> Model Awal Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin	91
Tabel 4.18	Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Bahan Makanan di Kota Jayapura.....	92
Tabel 4.19	Hasil Uji Residual <i>White Noise</i> Model Fungsi Transfer Inflasi Bahan Makanan Kota Jayapura.....	92
Tabel 4.20	Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Manokwari	96

Tabel 4.21	Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Manokwari	97
Tabel 4.22	Hasil Estimasi Parameter Model Awal Fungsi Transfer Multi Input Inflasi Bahan Makanan Kota Manokwari	99
Tabel 4.23	Nilai RMSE <i>in-sample</i> Fungsi Transfer antar Deret Input..	99
Tabel 4.24	Hasil Uji Residual <i>White Noise</i> Model Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin	100
Tabel 4.25	Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Sorong.....	103
Tabel 4.26	Uji Residual Model ARIMA ([1,12],0,[9]) untuk Tinggi Gelombang dan ARIMA ([1,9],0,0)(1,0,0) ¹² untuk Kecepatan Angin Kota Sorong.....	104
Tabel 4.27	Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Manokwari	105
Tabel 4.28	Hasil Estimasi Parameter Model Awal Fungsi Transfer Multi Input Inflasi Bahan Makanan Kota Sorong	106
Tabel 4.29	Nilai RMSE Fungsi Transfer antar Deret Input	107
Tabel 4.30	Hasil Uji Residual <i>White Noise</i> Model Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin	107
Tabel 4.31	Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1 ₁) Bobot Invers Jarak pada Tiga Kota di Pulau Papua	112
Tabel 4.32	Estimasi Parameter <i>Restricted Model</i> GSTAR-GLS (1 ₁) Bobot Invers Jarak Pada Tiga Kota di Pulau Papua	113
Tabel 4.33	Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1 ₁) Bobot NKS Pada Tiga Kota di Pulau Papua	115
Tabel 4.34	Estimasi Parameter <i>Restricted Model</i> GSTAR-GLS (1 ₁) Bobot Normalisasi Korelasi Silang Pada Tiga Kota di Pulau Papua	116

Tabel 4.35	Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1_1) Bobot NIPKS Pada Tiga Kota di Pulau Papua	118
Tabel 4.36	Estimasi Parameter <i>Restricted Model</i> GSTAR-GLS (1_1) Bobot Normalisasi Inferensia Parsial Korelasi Silang pada Tiga Kota di Pulau Papua.....	119
Tabel 4.37	Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1_1) Bobot Konektivitas pada Tiga Kota di Pulau Papua.....	120
Tabel 4.38	Estimasi Parameter <i>Restricted Model</i> GSTAR-GLS (1_1) Bobot Konektivitas pada Tiga Kota di Pulau Papua.....	121
Tabel 4.39	Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1_1) Bobot Matriks Segi Tiga Atas Pada Tiga Kota di Pulau Papua.....	123
Tabel 4.40	Estimasi Parameter <i>Restricted Model</i> GSTAR-GLS (1_1) Matriks Segi Tiga Atas Pada Tiga Kota di Pulau Papua.....	124
Tabel 4.41	Nilai AIC Residual Model GSTAR-GLS (1_1) (<i>Full Model</i>) Berdasarkan Bobot Lokasi Pada Data IBM Tiga Kota di Pulau Papua.....	126
Tabel 4.42	Nilai RMSE <i>Out-Sample</i> menurut bobot lokasi pada Pemodelan GSTAR-GLS (1_1)	127
Tabel 4.43	Nilai AICC pada Dugaan Model VAR	130
Tabel 4.44	Estimasi Parameter <i>Full Model</i> GSTARX-GLS ($[1,2]_1$) dengan Bobot Invers Jarak Pada $n_{i,t}$ IBM.....	132
Tabel 4.45	Estimasi Parameter <i>Restricted Model</i> GSTARX-GLS ($[1,2]_1$) dengan Bobot Invers Jarak Pada $n_{i,t}$ IBM.....	133
Tabel 4.46	Estimasi Parameter <i>Full Model</i> GSTARX-GLS ($[1,2]_1$) dengan Bobot Normalisasi Korelasi Silang Pada $n_{i,t}$ IBM...	135
Tabel 4.47	Estimasi Parameter <i>Restricted Model</i> GSTARX-GLS ($[1,2]_1$) dengan Bobot Normalisasi Korelasi Silang Pada $n_{i,t}$ IBM	136
Tabel 4.48	Estimasi Parameter <i>Full Model</i> GSTARX-GLS ($[1,2]_1$) dengan Bobot Normalisasi Inferensia Korelasi Silang Parsial pada $n_{i,t}$ IBM.....	138

Tabel 4.49	Estimasi Parameter <i>Restricted Model</i> GSTARX-GLS ([1,2] ₁) dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang Pada $n_{i,t}$ IBM.....	139
Tabel 4.50	Estimasi Parameter <i>Full Model</i> dari Model GSTARX-GLS ([1,2] ₁) dengan Bobot Konektifitas pada Residual IBM	141
Tabel 4.51	Estimasi Parameter <i>Restricted Model</i> dari Model GSTARX-GLS ([1,2] ₁) dengan bobot konektifitas pada $n_{i,t}$ IBM.....	142
Tabel 4.52	Estimasi Parameter <i>Full Model</i> dari Model GSTARX-GLS ([1,2] ₁) dengan Bobot Matriks Segi Tiga Atas pada Residual IBM.....	144
Tabel 4.53	Estimasi Parameter <i>Restricted Model</i> dari Model GSTARX-GLS ([1,2] ₁) dengan Bobot Matriks Segi Tiga Atas pada $n_{i,t}$ Inflasi Bahan Makanan.....	145
Tabel 4.54	Nilai RMSE <i>In-Sample</i> menurut bobot lokasi pada Pemodelan GSTARX-GLS ([1,2] ₁).....	147
Tabel 4.55	Nilai RMSE <i>Out-Sample</i> menurut bobot lokasi pada Pemodelan GSTARX -GLS ([1,2] ₁).....	148
Tabel 4.56	Nilai RMSE Data <i>Out-Sample</i> Hasil Pemodelan ARIMA, Fungsi Transfer, GSTAR-GLS (1 ₁) dan GSTARX-GLS ([1,2] ₁) pada data IBM di Pulau Papua.....	152

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Output SAS Hasil Estimasi Parameter <i>Full Model</i> GSTAR-GLS (1_1) pada Data Inflasi Bahan Makanan di Pulau Papua	163
Lampiran 2 Nilai AIC Residual Model GSTAR-GLS (1_1) (<i>Restricted</i> <i>Model</i>) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua.....	165
Lampiran 3 Nilai AIC Residual Model GSTARX-GLS ($[1,2]_1$) (<i>Full</i> <i>Model</i>) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua.....	166
Lampiran 4 Nilai AIC Residual Model GSTARX-GLS ($[1,2]_1$) (<i>Restricted Model</i>) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua	166
Lampiran 5 Proc ARIMA Univariate Inflasi Bahan Makanan di Kota Jayapura.....	167
Lampiran 6 Output SAS Model ARIMA $([9],0,0)$ Kota Jayapura.....	168
Lampiran 7 Output SAS Model ARIMA $([2,6],0,0)$ Kota Manokwari ..	169
Lampiran 8 Output SAS Model ARIMA $(1,0,0)$ Kota Sorong dengan Deteksi Outlier.....	170
Lampiran 9 Output SAS Model Fungsi Transfer $(2,0,0)$ Kota Jayapura	172
Lampiran 10 Output SAS Model Fungsi Transfer $(6,0,0)$ Kota Manokwari.....	173
Lampiran 11 Output SAS Model Fungsi Transfer $(0,[2],0)$ Kota Sorong	174
Lampiran 12 Output Uji Mc-Leod Li (1981) pada Residual Model ARIMA IBM di Pulau Papua	175
Lampiran 13 Output Uji Mc-Leod Li (1981) pada Residual Model Fungsi Transfer IBM di Pulau Papua	176

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Kenaikan harga barang dan jasa yang tidak terkendali pada suatu perekonomian dalam kurun waktu tertentu dapat memberikan beberapa efek negatif seperti adanya spekulasi distribusi barang, meningkatnya tingkat bunga perbankan dan berkurangnya nilai investasi di suatu wilayah (Sukirno, 2008). Dampak langsung yang terjadi ketika kenaikan harga komoditas barang dan jasa tidak terkendali yaitu menurunnya standar hidup masyarakat sebagai akibat terjadinya inflasi yang tidak stabil. Oleh karena itu, untuk mengurangi dampak negatif yang berkelanjutan, pemerintah melalui Bank Indonesia (BI) mengeluarkan beberapa kebijakan moneter yang harapannya dapat menciptakan kondisi inflasi yang ideal dan stabil.

Pada dasarnya inflasi secara matematis diperoleh dari rasio perubahan Indeks Harga Konsumen (IHK) periode tertentu dengan periode sebelumnya yang dihitung melalui 7 (tujuh) kelompok pengeluaran, yaitu (1) Bahan Makanan, (2) Barang jadi, rokok dan tembakau, (3) Perumahan, air, listrik dan gas, (4) Sandang, (5) Kesehatan, (6) Pendidikan rekreasi dan olah raga, (7) Transportasi, komunikasi dan jasa keuangan (Bank Indonesia, 2013). Besaran rasio perubahan (*volatile goods*) yang terjadi pada kelompok pengeluaran tersebut dapat disebabkan oleh beberapa faktor. Faktor-faktor yang mempengaruhi mekanisme harga pasar antara lain naiknya bahan baku produksi, naiknya permintaan barang dan jasa dibandingkan penawaran barang dan jasa tersebut, serta terganggunya distribusi barang dan jasa ke daerah tujuan.

Sejak tahun 2008, Sorong, Manokwari dan Jayapura tercatat sebagai tiga kota inflasi di pulau Papua. Fenomena perkembangan harga yang terjadi hampir serupa, dimana kelompok bahan makanan menjadi kelompok pengeluaran dengan andil terbesar dalam penggerak inflasi (Bank Indonesia, 2014). Hal ini juga didukung oleh hasil Survei Biaya Hidup (SBH) 2012, nilai konsumsi dasar terbesar berada pada kelompok pengeluaran bahan makanan sekitar 23,35%-

32,62% dari total pengeluaran rumah tangga setiap bulannya. Demikian pula dalam sub kelompok bahan makanan, komoditas padi-padian dan ikan segar menempati urutan pertama dan kedua dengan andil inflasi terbesar yaitu 18,8% - 23,48% (BPS, 2013).

Pangan merupakan kebutuhan dasar utama manusia yang harus selalu dipenuhi setiap saat. Namun, hingga tahun 2015 Pulau Papua masih masuk dalam kategori kawasan rawan pangan (BKPKP, 2015). Kendati Papua memiliki potensi wilayah yang luas, dikarenakan proses produksi yang masih bersifat tradisional dan ekstensif maka perlu adanya pengiriman bahan pangan dari daerah yang surplus produksi, khususnya Pulau Jawa (KADIN, 2011). Beberapa komoditas pangan yang didatangkan dari luar pulau Papua, antara lain beras, ayam, telur, bumbu-bumbuan serta sayur-sayuran tertentu (UNIPA, 2005; Bank Indonesia, 2014).

Dalam jalur distribusi bahan pangan tersebut, moda transportasi laut adalah moda transportasi yang efektif dan efisien di Kawasan Timur Indonesia. Jalur distribusi barang yang menggunakan moda transportasi laut menggunakan analisis *Transshipment* dengan mempertimbangkan hasil optimasi waktu, biaya, dan keselamatan dari berbagai alternatif jalur pelayaran. Oleh karenanya, Pelabuhan Bitung sebagai *Global Hub Port* menjadi pintu akses ke kawasan Pulau Maluku dan Papua. Adapun jalur pintu masuk ke Pulau Papua, Pelabuhan Sorong menjadi pelabuhan utama yang memiliki jalur pelayaran yang akan selalu dilewati antar berbagai pelabuhan dari dan keluar Pulau Papua. Hal ini disebabkan lokasi geografis pelabuhan Sorong yang berada pada ujung barat Pulau Papua, menjadikan pelabuhan Sorong sebagai jalur strategis pelayaran kapal (P4L, 2012).

Pendistribusian komoditas pangan di seluruh Pulau Papua, menggantungkan pada tiga pelabuhan utama yang strategis, yaitu Pelabuhan Sorong, Pelabuhan Manokwari dan Pelabuhan Jayapura. Jalur pendistribusian komoditas pangan yang berasal dari luar Papua mengikuti jalur pelayaran kapal PELNI dengan trayek yang umumnya hanya satu arah yang dimulai dari Pelabuhan Sorong menuju Pelabuhan Manokwari dan berakhir di Pelabuhan Jayapura yang kemudian didistribusikan kembali pada pelabuhan-pelabuhan kecil (PT. PELNI (Persero), 2016). Hambatan distribusi komoditas melalui transportasi

laut adalah tinggi gelombang dan cuaca buruk. Sehingga, ketika tinggi gelombang masuk dalam kategori cuaca buruk (ketinggian gelombang mencapai 3-4 meter) atau arah dan kecepatan angin tidak stabil pada awal jalur pelayaran utama, maka dapat dipastikan pelayaran kapal akan terhambat dan terlambat. Kondisi ini akan mempengaruhi aspek suplai barang yang pada akhirnya berdampak pula pada kenaikan harga barang.

Penelitian tentang efek cuaca yang mempengaruhi harga pangan pernah dilakukan oleh Rousant *et al.* (2003) menggunakan pendekatan model *Autoregressive Integrated Moving Average* (ARIMA). Kesimpulan yang diperoleh yaitu perlu adanya pemodelan dengan memasukan unsur musiman sehingga ketidakpastian harga pangan di Perancis dan Chicago dapat lebih mudah diramalkan, terutama pada bulan dengan cuaca ekstrim. Hardle dan Cabrera (2011) juga meneliti pengaruh cuaca terhadap harga pangan di Kawasan Eropa Barat, ditemukan bahwa penurunan suhu yang ekstrim dapat mempengaruhi resiko harga pasar (*market price of risk*).

Peramalan inflasi sebagai salah satu indikator ekonomi makro telah banyak menjadi fokus studi para peneliti. Tercatat 26.002 jurnal maupun *proceeding* di web site sience direct dan springer meneliti topik terkait. Hal ini menegaskan bahwa inflasi merupakan suatu indikator ekonomi makro yang sangat penting. Sebagai contoh, studi peramalan inflasi jangka panjang maupun jangka pendek pada beberapa negara Balkan dan Eropa dengan membandingkan model naive dan model ekonometrik lain (Central Bank of The Republic of Turkey, 2013; Czudaj, 2011; Pincheira & Medel, 2015). Selain itu, berbagai pendekatan peramalan dengan melibatkan variabel makro atau metode perhitungan terbaru juga banyak dilakukan meskipun kesimpulan yang didapatkan tidak selalu metode yang tidak parsimoni memberikan hasil peramalan yang akurat (Gonzalez *et al.*, 2010; Aidoo, 2010; Aron & Muellbauer, 2103; Chen *et al.*, 2014). Ketepatan peramalan inflasi cukup baik saat adanya penambahan variabel eksogen dengan memperhatikan efek musiman atau pengaruh wilayah sekitar (Saz, 2011).

Berdasarkan jenis persamaan yang membentuk model peramalan data time series, secara umum terdapat dua metode statistik yaitu Linear dan Non Linear. Metode statistik untuk model linier pada data univariat yaitu

Autoregressive (AR), *Moving Average* (MA), dan *Autoregressive Integrated Moving Average* (ARIMA). Penambahan variabel eksogen baik metrik maupun non metrik pada model linier diharapkan mampu meningkatkan performa model peramalan, sehingga penggunaan model ARIMA dengan penambahan variabel eksogen (ARIMAX) cukup sering digunakan dalam meramal data time series multivariat (Lim *et al.*, 2008; Altissimo *et al.*, 2009; Huitema, Houten, & Manal, 2014).

Pengaplikasian metode non-linear juga cukup berkembang, seperti *Artificial Neural Network* (ANN), *Neuro-Fuzzy* dan *Adaptive Neuro-Fuzzy Inference Sistem* (ANFIS). ANN merupakan metode non-linear yang memodelkan hubungan yang kompleks antara input dan output melalui pola data yang cara kerjanya meniru cara kerja jaringan syaraf manusia. Berbeda dengan ANN, Neuro-Fuzzy membentuk model peramalan yang dapat dijelaskan proses penalaran sesuai dengan aturan-aturan dalam basis pengetahuan yang sudah di definisikan sebelumnya, namun pada metode ini tidak dapat melakukan sistem pembelajaran seperti yang di lakukan oleh ANN. ANFIS muncul sebagai metode yang menggabungkan kelemahan dan kelebihan dari metode ANN dan Neuro-Fuzzy, sehingga kemampuan learning pada input dalam neural-network yang besar dapat memberikan hasil yang lebih akurat dalam waktu yang singkat (Khoshnevisan *et al.*, 2014).

Dalam model peramalan, terkadang peneliti kesulitan untuk menentukan variabel endogen maupun variabel eksogen karena dalam beberapa studi semua variabel yang terlibat saling berkaitan. Metode yang dapat menganalisis hal tersebut adalah *Vector Auto Regression* (VAR), suatu persamaan simultan yang menyatakan hubungan interdependensi antar variabel endogen pada model time series multivariat. Guerello (2014) menganalisis kebijakan ekonomi makro dalam mempenaruhi tingkat pinjaman bank di wilayah Eropa. Grossmann *et.al* (2014) menguji tingkat volatilitas nilai tukar uang terhadap perubahan variabel makro ekonomi di negara-negara berkembang. Pengembangan model VAR dengan penambahan variabel eksogen (VARX), selain dipengaruhi oleh variabel endogen lain dalam model juga dipengaruhi oleh variabel eksogen sehingga diharapkan model peramalan yang terbentuk akan lebih maksimal (Xiumei *et al.*, 2011).

Model time series multivariate yang melibatkan unsur tempat atau lokasi lain biasa disebut dengan model spatio temporal. Model ini didasari pada kenyataan bahwa akibat kondisi geografis dan keterbatasan infrastruktur di setiap wilayah, maka wilayah yang saling berdekatan memiliki keterkaitan dalam pemenuhan kebutuhan barang dan jasa. Keterkaitan antar wilayah tersebut memunculkan suatu kondisi, adanya perubahan harga di suatu wilayah sebagai akibat adanya pengaruh dari perubahan harga di wilayah sekitarnya. Sehingga dapat disimpulkan, inflasi yang pada dasarnya memiliki keterkaitan antar waktu juga memiliki keterkaitan antar wilayah (Hasbullah, 2012).

Pada awal perkembangan model spatio temporal, Pfeifer dan Deutsch (1980a; 1980b) memperkenalkan model *Space Time Autoregressive* (STAR), yaitu suatu model yang menggabungkan interdependensi waktu dan lokasi. Model STAR merupakan gabungan model *Autoregressive* orde p , $AR(p)$ dari Box-Jenkins dan model spatial yang melibatkan bobot antar lokasi. Model STAR ini masih mempunyai kelemahan pada fleksibilitas parameter yang mengasumsikan bahwa lokasi-lokasi yang diteliti memiliki karakteristik yang seragam sehingga kurang sesuai dengan tipe lokasi yang bersifat heterogen (Mulyaningsih, 2013).

Model *Generalized Space Time Autoregressive* (GSTAR) adalah penyempurnaan dari pemodelan STAR sehingga dapat digunakan untuk menjelaskan keterkaitan antar waktu dan lokasi yang heterogen (Ruchjana, 2002). Model GSTAR memungkinkan nilai parameter autoregressive (AR) bervariasi pada setiap lokasi. Beberapa peneliti menggunakan model GSTAR dalam penelitian yang dilakukannya, seperti Wutsqa dan Suhartono (2010) menggunakan GSTAR dalam melakukan pemodelan Produksi Domestik Bruto (PDB) di negara-negara Eropa Barat. Muryanto (2016) melakukan Pemodelan GSTARX untuk meramalkan Indeks Harga Konsumen (IHK) di beberapa kota inflasi di Pulau Kalimantan dengan melibatkan variabel eksogen berupa jumlah uang beredar (*inflow outflow*).

Terkait dengan estimasi parameter, pada awalnya estimasi parameter pada pemodelan spatial temporal masih terbatas pada maximum likelihood dan *ordinary least square* (OLS). Terzi (1995) berpendapat bahwa penggunaan estimasi parameter dengan metode OLS pada GSTAR kurang efisien jika residual

antar lokasi saling berkorelasi. Zellner (1962) memperkenalkan model seemingly unrelated regression (SUR), suatu sistem persamaan yang terdiri dari beberapa persamaan regresi yang memiliki residual yang saling berkorelasi. Greene (2007) mengestimasi model SUR dengan menggunakan generalized least square (GLS). Sehingga dalam perkembangan pemodelan spatio temporal yang melibatkan variabel eksogen diterapkan pemodelan GSTARX dengan metode estimasi parameter GLS atau biasa yang dikenal dengan GSTARX-GLS (Wahyuningrum, 2014).

Selain penentuan parameter GSTAR, penentuan bobot lokasi merupakan salah satu masalah utama karena akan mempengaruhi model yang terbentuk (Ruchjana, 2002 ; Suhartono & Subanar, 2006). Karakteristik model space-time adalah korelasi dalam waktu maupun lokasi yang diinterpretasikan dalam matriks bobot \mathbf{W} dengan ukuran $N \times N$. Beberapa penelitian sebelumnya, menggunakan bobot matriks berupa bobot seragam, biner, invers jarak, normalisasi korelasi silang, dan inferensia parsial korelasi silang. Namun, penggunaan bobot lokasi tersebut di atas sudah tidak relevan jika interaksi antar wilayah tidak dua arah. Sebagai contoh, jalur distribusi pangan dari luar pulau Papua hanya berlaku satu arah, dimulai dari pelabuhan Sorong menuju pelabuhan Manokwari dan berakhir di pelabuhan Jayapura. Sehingga untuk kasus tersebut, perlu adanya pembobotan ulang dengan memberlakukan matriks segi tiga atas (*Upper Triangular Matrix*) yang menyatakan hubungan satu arah.

Hingga saat ini belum ada penelitian yang secara spesifik menganalisis inflasi di Papua dengan melibatkan unsur pengaruh interaksi antar wilayah dan variabel prediktor. Sehingga penulis mengusulkan suatu pendekatan metode baru pada pembobot lokasi model GSTARX, yaitu matriks segi tiga atas (*Upper Triangular Matrix*) dengan melibatkan variabel prediktor berupa faktor cuaca.

1.2 Perumusan Masalah

Peramalan data time series tidak hanya mengandung keterkaitan antar kejadian pada waktu sebelumnya, tetapi juga dipengaruhi oleh ketekaitan antar lokasi dan variabel eksogen lainnya. Berdasarkan permasalahan tersebut maka rumusan masalah dalam penelitian ini yaitu:

1. Bagaimana pemodelan GSTARX dalam menjelaskan pengaruh variabel eksogen terhadap inflasi bahan makanan di Papua?
2. Bagaimana nilai peramalan inflasi bahan makanan di Papua satu tahun ke depan menggunakan model GSTARX?
3. Bagaimana keterbandingan akurasi nilai peramalan GSTARX, GSTAR, Fungsi Transfer dan ARIMA?

1.3 Tujuan Penelitian

Berdasarkan rumusan permasalahan diatas tujuan penelitian ini, yaitu :

1. Memperoleh model GSTARX inflasi bahan makanan di Pulau Papua.
2. Memperoleh nilai peramalan inflasi bahan makanan di Papua menggunakan model GSTARX yang terbentuk.
3. Memperoleh keterbandingan akurasi pemodelan GSTARX, GSTAR, Fungsi Transfer dan ARIMA dalam meramalkan inflasi bahan makanan di Pulau Papua.

1.4 Manfaat Penelitian

Manfaat yang ingin dicapai dalam penelitian ini yaitu dapat memberikan suatu model yang mampu menjelaskan keterkaitan antar wilayah dan faktor cuaca sebagai variabel eksogen. Hasil peramalan model terbaik dapat menjadi rekomendasi Tim Pengendalian Inflasi Daerah (TPID) dalam melakukan koordinasi dan sinkronisasi kebijakan daerah untuk mengatasi permasalahan keterjangkauan barang dan jasa melalui Rapat Koordinasi Wilayah TPID, Rapat Koordinasi Pusat dan Daerah serta Rapat Koordinasi Nasional TPID, khususnya antar wilayah di Pulau Papua.

1.5 Batasan penelitian

Batasan masalah pada penelitian ini yaitu pada variabel eksogen berupa faktor cuaca yang didefinisikan sebagai tinggi gelombang (*wave height*) dan kecepatan angin. Data bersumber dari website satelit cuaca eropa yaitu <http://apps.ecmwf.int/datasets/data/interim-full-daily>. Selain itu, data inflasi yang digunakan adalah inflasi kelompok bahan makanan pada tiga kota inflasi di

Papua, yaitu Jayapura, Manokwari dan Sorong dan dapat diperoleh dari publikasi BPS. Waktu penelitian dibatasi dari bulan Januari 2008 sampai dengan Desember 2015.

BAB 2

TINJAUAN PUSTAKA

Pada bab ini menerangkan beberapa teori yang menjadi dasar penggunaan metode analisis dalam menyelesaikan permasalahan pada penelitian ini, meliputi konsep dasar *time series*, ARIMA model fungsi transfer, dan GSTARX dengan berbagai pendekatan penimbang. Selain itu konsep definisi perhitungan Inflasi dan faktor cuaca sebagai variabel eksogen turut dijelaskan lebih rinci.

2.1 Model Time Series

Model time series merupakan suatu model yang mempelajari pola hubungan data pada interval waktu yang teratur. Model time series banyak digunakan untuk menganalisa data-data ekonomi dan bisnis, baik model univariat maupun multivariat. Dalam konteks ini model time series yang diperoleh memuat ukura-ukuran yang dapat digunakan untuk membuat keputusan pada saat ini.

2.2 Metode ARIMA Box Jenkins

Pemilihan model ARIMA yang sesuai untuk suatu data deret waktu dapat menggunakan prosedur Box-Jenkins. Tahap awal identifikasi dilakukan dengan mengamati plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data yang selanjutnya digunakan untuk mendapatkan dugaan sementara model ARIMA yang sesuai. Tahap selanjutnya melakukan estimasi dan uji signifikansi parameter apakah model dugaan sementara yang telah diestimasi cukup sesuai dengan data deret waktunya.

Model deret waktu dengan data yang stasioner melalui proses *differencing* disebut sebagai model ARIMA. Dengan demikian, jika p menunjukkan orde AR, d tingkat proses *differencing* dan q menunjukkan orde MA maka model ARIMA memiliki ordo (p,d,q) . Jika data telah stasioner tanpa perlu proses *differencing* d kali, maka model yang terbentuk menjadi ARIMA $(p, 0, q)$

atau model ARMA (p, q) . Model ARIMA (p, d, q) secara umum dapat ditulis sebagai berikut (Wei, 2006):

$$\phi(B)(1 - B)^d Y_t = \theta_0 + \theta_q(B)a_t$$

dengan :

$$\theta_0 = \text{Konstanta}$$

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$B = \text{backward shift operator, } B^k Y_t = Y_{t-k}$$

$$a_t = \text{residual yang white noise dengan mean nol dan varians } \sigma_a^2.$$

2.2.1. Identifikasi Model ARIMA (p,d,q)

Identifikasi model ARIMA (p, d, q) dapat dilakukan dengan beberapa langkah sebagai berikut, yaitu (Wei, 2006) :

1. Melakukan plotting data *time series* dan memilih jenis transformasi yang sesuai.

Asumsi dasar yang harus dipenuhi dalam penggunaan analisis deret waktu adalah stasioneritas data. Syarat-syarat yang harus dipenuhi dalam stasioneritas adalah sebagai berikut:

1. Stasioner dalam varians (varians konstan); $\text{Var}(Y_t) = \text{Var}(Y_{t+k})$, dimana Y_t adalah variabel dependen pada waktu t .
2. Stasioner dalam *mean* (rata-rata konstan); $E(Y_t) = E(Y_{t+k})$.

Kestasioneran varians dapat dideteksi dari nilai varians data yang bersifat konstan atau dinotasikan dengan $V(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0$. Untuk mengatasi data dengan varians tidak homogen dapat dilakukan dengan transformasi. Metode transformasi yang sering digunakan adalah model transformasi yang diperkenalkan oleh Box dan Cox pada tahun 1964, yaitu:

$$T(Y_t) = Y_t^{(\lambda)} = \frac{Y_t^\lambda - 1}{\lambda},$$

dengan λ adalah parameter transformasi (Wei, 2006).

Bentuk transformasi Box-Cox untuk beberapa nilai estimasi λ yang sering digunakan ditunjukkan pada Tabel 2.1.

Tabel 2.1 Nilai Transformasi Box Cox

Nilai λ	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0,0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1,0	Y_t tidak ditransformasi

Sumber : Wei (2006)

Uji stasioneritas varians tersebut ditampilkan dalam bentuk plot *Box-Cox*. Jika nilai batas bawah dan batas atas *lambda* dari data *time series* mengandung nilai satu, maka varians data tersebut sudah stasioner.

2. Menghitung dan memeriksa nilai ACF dan PACF dari data awal untuk menentukan tingkat *differencing* yang diperlukan sehingga dapat stasioner dalam mean. Berikut aturan umum yang dapat diikuti :
 - a. Jika plot ACF turun melambat dan PACF *cut off* setelah lag 1, hal ini mengindikasikan bahwa proses *differencing* diperlukan (Wei, 2006). Kita dapat mencoba melakukan *first differencing* $(1 - B)Y_t$. Kita juga dapat menggunakan unit root test yang diusulkan oleh Dickey dan Fuller (1979) dalam Wei (2006).
 - b. Secara umum untuk mengatasi non-stasioner kita dapat mempertimbangkan tingkat *differencing* yang lebih tinggi $(1 - B)^d Y_t$ untuk $d > 1$. Pada kasus yang umum, d yang manapun 0, 1, atau 2. Sebagai catatan jika $(1 - B)^d Y_t$ stasioner maka $(1 - B)^{d+i} Y_t$ untuk $i = 1, 2, \dots$ juga stasioner.
3. Menghitung dan memeriksa ACF dan PACF dari data yang telah stasioner, berdasarkan pola teoritik untuk menentukan order dari p dan q . Sebagai panduan pola teoritik tersebut dapat dilihat pada Tabel 2.2.

Tabel 2.2 Pola Teoritik ACF dan PACF dari Proses Stasioner

Proses	ACF	PACF
AR(p)	<i>Dies down</i> (turun cepat secara eksponensial/sinusoidal)	<i>Cuts off after lag p</i> (terputus setelah lag p)
MA(q)	<i>Cuts off after lag q</i> (terputus setelah lag q)	<i>Dies down</i> (turun cepat secara eksponensial / sinusoidal)
ARMA(p,q)	<i>Dies down after lag (q-p)</i> (turun cepat setelah lag (q-p))	<i>Dies down after lag (p-q)</i> (turun cepat setelah lag (p-q))

Sumber : Wei, 2006

2.2.2. Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Suatu deret time series $Y_1, Y_2, Y_3, \dots, Y_n$ dengan rata-rata $\mu = E(Y_t) = E(Y_{t+k})$ dan $Var(Y_t) = E(Y_t - \mu_t)^2 = \sigma^2$ dengan varians yang konstant. Maka sampel ACF dapat di definisikan sebagai berikut :

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

dengan $\bar{Y} = \sum_{t=1}^n \frac{Y_t}{n}$.

Dengan demikian, suatu proses stasioner jika dari fungsi autokorelasi memiliki sifat-sifat sebagai berikut :

1. $\gamma_0 = Var(Y_t); \rho_0 = 1$.
2. $|\rho_k| \leq \gamma_0; |\rho_k| \leq 1$.
3. $\gamma_k = -\gamma_k$ dan $\rho_k = \rho_{-k}$ untuk semua k .

Nilai PACF dalam analisis deret waktu $\hat{\phi}_{kk}$ dimulai dengan menghitung $\hat{\phi}_{11} = \hat{\rho}_1$, sedangkan untuk menghitung $\hat{\phi}_{kk}$ digunakan formula sebagai berikut (Wei, 2006) :

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}$$

dan $\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}$ dengan $j=1,2,\dots, k$.

2.2.3. Estimasi dan Uji Signifikansi Parameter

Wei (2006) dalam bukunya menyebutkan beberapa metode estimasi parameter model ARIMA, antar lain Metode *Moment*, Metode *Maximum Likelihood*, Estimasi Nonlinier dan Estimasi *Ordinary Least Square* (OLS). Pada

penelitian ini metode estimasi parameter yang digunakan yaitu Metode *Maksimum Likelihood*, karena banyaknya sifat-sifat dari estimator yang baik pada metode tersebut. Misalnya, model sementara kita adalah ARMA (p,q) dengan parameter yang diestimasi $\phi = (\phi_1, \phi_2, \dots, \phi_p)'$, $\mu = E(Y_t)$, $\theta = (\theta_1, \theta_2, \dots, \theta_p)'$ dan $\sigma_a^2 = E(a_t)$ dengan model:

$$\begin{aligned} \dot{Y}_t = & \phi_1 \dot{Y}_{t-1} + \phi_2 \dot{Y}_{t-2} + \dots + \phi_p \dot{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \\ & \theta_{t-q} a_{t-q} , \end{aligned} \quad (2.1)$$

dimana $\dot{Y}_{t-1} = Y_t - \mu$ dengan $Y_t (t = 1, 2, \dots, n)$ adalah n observasi yang telah stasioner atau data *time series* yang telah di transformasi dan stasioner serta $\{\hat{a}_t\}$ adalah i.i.d $N(0, \sigma_a^2)$ *white noise*. maka fungsi peluang bersama dari $a_t = (a_1, a_2, \dots, a_n)'$, yaitu :

$$P(a|\phi, \mu, \theta, \sigma_a^2) = (2\pi\sigma_a^2)^{-n/2} \exp\left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right].$$

Persamaan 2.1 dapat ditulis dengan persamaan sebagai berikut :

$$a_t = \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_{t-q} a_{t-q} + \dot{Y}_{t-1} \phi_1 \dot{Y}_{t-1} - \phi_2 \dot{Y}_{t-2} + \dots - \phi_p \dot{Y}_{t-p} ,$$

sehingga kita dapat menuliskan fungsi likelihood dari parameter $(\phi, \mu, \theta, \sigma_a^2)$. Misalkan $Y = (Y_1, Y_2, \dots, Y_n)'$, dengan asumsi suatu kondisi awal $Y_* = (Y_{1-p}, \dots, Y_{-1}, Y_0)'$ dan $a_* = (a_{1-q}, \dots, a_{-1}, a_0)'$. Fungsi syarat *log-likelihood* bersama yaitu:

$$\ln L_*(\phi, \mu, \theta, \sigma_a^2) = -\frac{n}{2} \ln 2\pi\sigma_a^2 + \frac{S_*(\phi, \mu, \theta)}{2\sigma_a^2} ,$$

dimana,

$$S_*(\phi, \mu, \theta) = \sum_{t=1}^n a_t^2 (\phi, \mu, \theta | Y_*, a_* Y) , \quad (2.2)$$

adalah fungsi *conditional sum of square*. Nilai $\hat{\Phi}, \hat{\mu}, \hat{\theta}$ diperoleh dengan memaksimumkan persamaan 2.2 atau biasa disebut estimator maximum likelihood bersyarat. Dikarenakan $\ln L_*(\phi, \mu, \theta, \sigma_a^2)$ mengikutsertakan data hanya melalui $S_*(\phi, \mu, \theta)$ maka untuk mendapatkan estimator ini sama dengan meminimumkan fungsi *conditional sum of square* $S_*(\phi, \mu, \theta)$ dimana pada persamaan tersebut sudah tidak mengandung parameter σ_a^2 .

Terdapat beberapa alternatif untuk menetapkan kondisi awal untuk Y_* dan a_* . Asumsi $\{Y_t\}$ adalah proses stasioner dan $\{a_t\}$ adalah *error* yang telah *white*

(*white noise error*) i.i.d $N(0, \sigma_a^2)$ maka kita mengganti vektor matriks Y yang tidak diketahui dengan rata-rata sampel \bar{Y} dan *error* a_t yang tidak diketahui digantikan dengan nilai ekspektasi 0. Sehingga untuk persamaan 2.1 kita mengasumsikan $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ dan menghitung nilai a_t untuk $t \geq (p+1)$ menggunakan persamaan 2.2. Dengan demikian fungsi *conditional sum of square* dapat ditunjukkan pada persamaan 2.3 yaitu :

$$S_*(\phi, \mu, \theta) = \sum_{t=p+1}^n a_t^2(\phi, \mu, \theta|Y). \quad (2.3)$$

Setelah mendapatkan parameter model, maka uji parameter model dapat dilakukan untuk melihat kelayakan model tersebut. Model dianggap layak jika memiliki parameter yang signifikan. Hipotesis yang digunakan dalam uji signifikansi parameter adalah sebagai berikut:

$$H_0: \beta = 0$$

$$H_1: \beta \neq 0$$

dengan $\hat{\beta}$ adalah estimasi parameter model, statistik uji yang digunakan adalah uji t , yaitu :

$$t_{hit} = \frac{\hat{\beta}}{se(\hat{\beta})}.$$

Daerah penolakan H_0 adalah $|t_{hit}| > t_{(\frac{\alpha}{2}, n-n_p)}$, dimana n_p adalah jumlah parameter dalam model.

2.2.4. Uji Kesesuaian Model

Uji kesesuaian model dilakukan terhadap residual dari model. Model dianggap telah sesuai jika asumsi residual telah *white noise* terpenuhi. Asumsi *white noise* adalah suatu kondisi residual dengan rata-rata nol dan varians konstan (σ_a^2) yang identik, independen dan berdistribusi normal. Pengujian asumsi residual yang saling tidak berkorelasi dapat menggunakan Q-statistik (Uji Ljung-Box) dan asumsi residual normal dapat menggunakan uji Kolmogorov-Smirnov. Sedangkan pengujian asumsi varian yang konstan dapat menggunakan uji McLeod dan Li (Wei, 2006).

a. Residual (a_t) bersifat *white noise*

Asumsi residual yang bersifat *White noise* artinya tidak terdapat korelasi antar residual, tidak terdapat pola pada plot ACF maupun PACF serta tidak

signifikan pada α yang telah ditentukan. Hipotesis yang digunakan dalam uji Ljung-Box yaitu :

$$H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0 \text{ (tidak ada korelasi antar residual)}$$

$$H_1: \text{minimal ada satu } \rho_k \neq 0 ; k = 1, 2, 3, \dots, K$$

dengan statistik uji sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)},$$

dimana Q mengikuti distribusi $\chi_{(K-m)}^2$ dengan $m = p + q$. Daerah penolakan H_0 adalah $Q > \chi_{\alpha; K-p-q}^2$.

b. Residual (a_t) berdistribusi normal

Uji kenormalan terhadap residual model dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hipotesis pada uji kenormalan adalah sebagai berikut:

$$H_0: F(a_t) = F_0(a_t), \text{ untuk semua } a_t$$

$$H_1: F(a_t) \neq F_0(a_t), \text{ untuk semua } a_t$$

Dengan statistik uji yaitu:

$$D = \sup |S(a_t) - F_0(a_t)|,$$

$S(a_t)$ = fungsi distribusi data residual yang belum diketahui

$F(a_t)$ = fungsi distribusi kumulatif dari data asal residual

Daerah penolakan H_0 jika $D_{hit} \geq D_{\alpha, n}$ atau jika $p\text{-value} < \alpha$. Nilai kritis $D_{\alpha, n}$ dapat diperoleh dari tabel Kolmogorov Smirnov dengan jumlah sampel dan α yang bersesuaian.

c. Varians residual (a_t) konstant

a_t adalah suatu residual yang tidak berkorelasi namun memiliki varians yang berubah seiring waktu, maka pengujian apakah residual a_t bersifat konstan dapat menggunakan uji McLeod-Li. Tahap awal prosedur pengujian McLeod-Li dimulai dengan mengkuadratkan estimasi residual (\hat{a}_t^2) dari model yang terbentuk dan menghitung nilai ACF berdasarkan persamaan berikut :

$$\hat{\rho}_i(\hat{a}_t^2) = \frac{\sum_{t=1}^{n-i} (\hat{a}_t^2 - \hat{\sigma}^2)(\hat{a}_{t+i}^2 - \hat{\sigma}^2)}{\sum_{t=1}^n (\hat{a}_t^2 - \hat{\sigma}^2)^2}$$

$$\text{dengan } \hat{\sigma}^2 = \frac{1}{n} \sum_{t=1}^n \hat{a}_t^2.$$

Hipotesis pada uji McLeod-Li yaitu :

$H_0: \rho_1(\hat{a}_t^2) = \rho_2(\hat{a}_t^2) = \dots = \rho_K(\hat{a}_t^2) = 0$ (varians antar residual konstan)

H_1 : minimal ada satu $\rho_k(\hat{a}_t^2) \neq 0$; $i = 1, 2, 3, \dots, K$

dengan statistik uji sebagai berikut:

$$Q(k) = n(n+2) \sum_{i=1}^K \frac{\hat{\rho}_i^2(\hat{a}_t^2)}{(n-k)},$$

dimana $Q(k)$ mengikuti distribusi $\chi_{(k)}^2$ dan daerah penolakan H_0 adalah $Q(k) > \chi_{(k)}^2$.

2.2.5. Peramalan ARIMA

Peramalan model ARIMA dapat dengan meminimumkan rata-rata akar kuadrat. Berdasarkan persamaan 2.1 model ARIMA $(p, 0, q)$, kita dapat menulis ulang persamaan tersebut menjadi persamaan berikut :

$$\phi(B) \dot{Y}_t = \theta(B) a_t.$$

Dikarenakan model tersebut stasioner tanpa perlu proses *differencing* maka dapat ditulis dalam bentuk representasi model *Moving Average* (MA), yaitu:

$$\begin{aligned} Z_t &= \psi(B) a_t \\ &= a_1 + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \\ &= \sum_{j=0}^{\infty} \psi_j a_{n+l-j}. \end{aligned}$$

Sehingga peramalan Z_{n+l} untuk $t = n, n-1, n-2, \dots$. Persamaan 2.4 dapat kita minimumkan peramalan rata-rata error kuadrat $\hat{Z}_n(l)$ dari Z_{n+l}

$$\hat{Z}_n(l) = \psi_l^* a_n + \psi_{l+1}^* a_{n-1} + \dots, \quad (2.4)$$

dimana ψ_j^* ditentukan. Sehingga, rata-rata *error* kuadrat dari peramalan adalah

$$E \left(Z_{n+l} - \hat{Z}_n(l) \right)^2 = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2 + \sigma_a^2 \sum_{j=0}^{\infty} [\psi_{l+j} - \psi_{l+j}^*]^2. \quad (2.5)$$

Persamaan tersebut dapat lebih mudah diminimumkan ketika $\psi_{l+j}^* = \psi_{l+j}$ sehingga $\hat{Z}_n(l) = \psi_l a_n + \psi_{l+1} a_{n-1} + \psi_{l+2} a_{n-2} + \dots$ dimana menggunakan persamaan 2.5 maka :

$$E(a_{n+j} | Z_n, Z_{n-1}, \dots) = \begin{cases} 0, & j > 0 \\ a_{n+j}, & j \leq 0 \end{cases}$$

Sehingga, untuk meramal $n + l$ waktu kedepan dapat ditulis dengan persamaan berikut :

$$E(Z_{n+l}|Z_n, Z_{n-1}, \dots) = \psi_l a_n + \psi_{l+1} a_{n-1} + \psi_{l+2} a_{n-2} + \dots ,$$

dengan meminimumkan rata-rata akar kuadrat, peramalan Z_{n+l} didapatkan dari ekspektasi bersyarat, yaitu:

$$\hat{Z}_n(l) = E(Z_{n+l}|Z_n, Z_{n-1}, \dots).$$

2.3 Deteksi *Outlier*

Data time series terkadang dipengaruhi oleh suatu kejadian yang tidak terduga, seperti wabah penyakit, perang, krisis politik atau ekonomi yang menyebabkan ketidak konsistenan seriesnya. Data seperti ini disebut dengan *outlier*. Ketika waktu dan penyebab ketidakkonsistenan data diketahui maka efek gangguan tersebut dapat dimodelkan dengan intervensi model. Namun, penyebab dari ketidakkonsistenan tersebut terkadang tidak diketahui. Jika outlier diabaikan maka hasil inferensia tidak *reliable* dan valid.

Deteksi outlier pertama kali diperkenalkan oleh Fox 1972 (Wei, 2006). Outlier terdiri dari beberapa tipe, yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS) dan *Temporary Change* (TC). Deret data time *outlier* pada deret data time series dapat diatasi dengan memasukkan *outlier* dalam model hingga mendapatkan model yang memenuhi asumsi *white noise* dan kenormalan.

2.3.1. *Additive Outlier* (AO)

Additive Outlier (AO) merupakan kejadian yang mempengaruhi suatu deret waktu pada satu waktu saja. Model AO dapat ditulis sebagai berikut (Wei, 2006) :

$$\begin{aligned} Y_t &= \begin{cases} u_t & , t \neq T \\ u_t + \omega & , t = T \end{cases} \\ &= u_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)} , \end{aligned}$$

dengan

$$I_t^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases}$$

u_t adalah model ARIMA sebelum deteksi *outlier*

$I_t^{(T)}$ adalah variabel *outlier* pada waktu ke- T .

2.3.2. *Innovational Outlier (IO)*

Efek dari *innovational outlier* pada suatu deret waktu adalah lebih rumit jika dibandingkan ketiga tipe *outlier* lainnya. Wei (2006) mendefinisikan model IO sebagai berikut :

$$\begin{aligned} Y_t &= u_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}) \end{aligned}$$

Efek AO hanya terjadi pada T observasi saja, sedangkan pada IO mempengaruhi seluruh observasi Y_t, Y_{t+1}, \dots melewati waktu T sepanjang memori dari sistem yang diberikan oleh $\frac{\theta(B)}{\phi(B)}$. Secara umum dalam data *time series* dapat mengandung beberapa *outlier* dengan tipe yang berbeda-beda, sehingga dapat dituliskan model *outliernya* secara umum sebagai berikut:

$$Y_t = \sum_{h=1}^H \omega_h v_h(B) I_t^{(T_h)} + u_t ,$$

dengan

$$\begin{aligned} u_t &= \frac{\theta(B)}{\phi(B)} a_t, \\ v_h(B) &= \begin{cases} 1 & , \text{ untuk AO} \\ \frac{\theta(B)}{\phi(B)} & , \text{ untuk IO} \end{cases} \end{aligned}$$

$I_t^{(T)}$ adalah variabel *outlier* pada waktu ke- T .

2.3.3. *Level Shift (LS)*

Level Shift adalah kejadian yang mempengaruhi deret pada satu waktu tertentu dan efek yang diberikan memberikan suatu perubahan yang tiba-tiba dan permanen. Model LS dapat dinyatakan dengan (Wei, 2006):

$$Y_t = u_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} .$$

2.3.4. *Temporary Change (TC)*

Temporary Change (TC) outlier adalah tipe *outlier* yang menghasilkan efek awal pada waktu ke t sebesar ω_t dan kemudian efek itu berangsur menghilang secara perlahan sesuai dengan besarnya δ . Model TC dapat ditulis dalam persamaan berikut :

$$Y_t = u_t + \frac{1}{(1-\delta B)} \omega_c I_t^{(T)} \text{ dengan } 0 \leq \delta \leq 1 .$$

Pada saat $\delta = 0$ maka TC akan menjadi kasus AO sedangkan pada saat $\delta = 1$ maka TC akan menjadi kasus LS.

2.4 Model Fungsi Transfer

Model fungsi transfer merupakan pengembangan dari metode *Box-Jenkins*, dimana terdapat dua atau lebih variabel yang dilibatkan dalam model dengan masing-masing variabel memiliki model ARIMA tertentu. Model fungsi transfer awalnya dikenalkan pada proses peramalan suatu variabel deret waktu dalam bidang industri kimia. Misalkan suatu variabel deret waktu y_t yang didefinisikan sebagai sejumlah produk hasil dari proses kimia yang dipengaruhi oleh suatu variabel x . Setiap perubahan variabel x tidak secara langsung memberikan efek pada variabel y , akan tetapi perubahan variabel x mempengaruhi variabel y_t satu atau dua waktu setelahnya. Proses tersebut dapat dikatakan sebagai respon dinamis atau jika dalam bentuk model persamaan disebut dengan model fungsi transfer (*Transfer Function Model*). Seiring perkembangan ilmu pengetahuan model fungsi transfer tidak hanya mampu menjelaskan proses dalam industri kimia tetapi juga dalam bidang ilmu ekonomi dan sistem bisnis.

Bentuk umum model fungsi transfer untuk *input* tunggal (x_t) dan *output* tunggal (y_t) adalah sebagai berikut (Wei, 2006):

$$y_t = v_0 x_t + v_1 x_{t-1} + v_2 x_{t-2} + \dots + n_t,$$

atau

$$y_t = v(B)x_t + n_t ,$$

dengan

y_t = representasi dari deret *output* yang stasioner.

x_t = representasi dari *input* yang stasioner.

n_t = representasi dari variabel *error* (deret *noise*) yang mengikuti suatu model ARIMA tertentu.

$v(B) = v_0 + v_1B + v_2B^2 + \dots + v_kB^k$ merupakan koefisien model fungsi transfer atau bobot respon impuls, yaitu susunan bobot pengaruh deret *input* x_t terhadap deret *output* y_t dalam sistem dinamis terhadap seluruh periode waktu yang akan datang. Bobot respon impuls dapat dinyatakan sebagai berikut:

$$v(B) = \frac{\omega_s(B)B^b}{\delta_r(B)},$$

dan

$$n_t = \frac{\theta_q(B)}{\phi_p(B)} a_t,$$

sehingga

$$y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} x_t + \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.6)$$

b = banyaknya periode sebelum deret *input* mulai berpengaruh terhadap deret *output*.

$$\omega_s(B) = (\omega_0 - \omega_1B - \omega_2B^2 - \dots - \omega_sB^s),$$

merupakan operator dengan orde s , yang mempresentasikan jumlah pengamatan masa lalu x_t yang berpengaruh terhadap y_t .

$$\delta_r(B) = (1 - \delta_1B - \delta_2B^2 - \dots - \delta_rB^r),$$

merupakan operator dengan orde r , yang mempresentasikan jumlah pengamatan masa lalu dari deret *output* itu sendiri yang berpengaruh terhadap y_t .

$$\theta_q(B) = \text{merupakan operator moving average orde ke-} q \text{ dari } n_t.$$

$$\phi_p(B) = \text{merupakan operator autoregressive orde ke-} p \text{ dari } n_t.$$

Tahap-tahap pembentukan fungsi transfer serupa dengan pembentukan model ARIMA yang dapat diilustrasikan dalam beberapa langkah berikut (Wei,2006), yaitu :

Tahap 1 : Identifikasi Model Fungsi Transfer

- a. Mempersiapkan deret *input* dan deret *output*. Deret *input* dan deret *output* sudah harus memenuhi asumsi stasioneritas sebelum digunakan dalam model fungsi transfer.

- b. *Prewhitening* deret *input* dan deret *output*

Deret *input* yang berautokorelasi menyebabkan fungsi *cross-correlation* antara deret *input* dan *output* memberikan kesimpulan yang salah dalam hal seberapa besar kekuatan dan arah korelasi antara dua variabel random tersebut. Untuk mengatasi hal tersebut, maka dilakukan *prewhitening* dengan mengasumsikan deret *input* x_t mengikuti proses ARIMA, yaitu :

$$\phi_x(B)x_t = \theta_x(B)\alpha_t .$$

dimana α_t adalah *white noise*. Deret α_t yaitu :

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} x_t ,$$

disebut deret *input* yang telah di *prewhitening*. Demikian pula dengan deret *output*, proses *prewhitening* pada deret *output* juga dilakukan dengan pola yang sama dengan proses *prewhitening* pada deret *input*. Sehingga deret *output* yang telah melalui proses *prewhitening* dapat ditulis sebagai berikut :

$$\beta_t = \frac{\phi_y(B)}{\theta_y(B)} y_t .$$

- c. Menghitung autokorelasi silang dan autokorelasi untuk deret *input* dan deret *output* yang telah melalui proses *prewhitening*. Hasil *Cross Correlation Function* (CCF) pada deret *input* dan deret *output* yang telah melalui proses *prewhitening* dapat memberikan indikasi yang sebenarnya dari hubungan kedua deret tersebut, baik dari kekuatan dan arah hubungan kedua variabel acak pada selisih waktu k . Sampel CCF dapat dinyatakan dalam persamaan berikut :

$$\rho_{\alpha\beta}(k) = \frac{\gamma_{\alpha\beta}(k)}{\sigma_{\alpha}\sigma_{\beta}} , k=0, \pm 1, \pm 2,$$

Untuk deret *input* yang telah melalui proses *prewhitening* (α_t) seharusnya sudah tidak ada autokorelasi yang signifikan, tetapi pada deret *output* yang diharapkan berbeda. Pada deret *output* yang telah melalui proses *prewhitening* (β_t) tetap ada autokorelasi yang signifikan dalam pembentukan fungsi transfer.

- d. Penetapan orde (b, r, s) untuk model fungsi transfer. Tiga nilai penting dalam sebuah fungsi transfer adalah (b, r, s), suatu orde dalam fungsi transfer. Nilai b menunjukkan periode deret *input* mulai berpengaruh terhadap deret *output*, sedangkan nilai s menunjukkan efek berapa lama deret *output* dipengaruhi oleh deret *input* dan r mengindikasikan lamanya deret *output* memiliki hubungan dengan nilai periode sebelumnya dari deret *output* itu sendiri.

- e. Penghitungan deret gangguan (*noise series*)

Setelah orde fungsi transfer diketahui, maka dapat dilakukan penghitungan nilai estimasi dari deret gangguan berikut :

$$\begin{aligned}\hat{n}_t &= y_t - \hat{v}(B)x_t \\ &= y_t - \frac{\hat{\omega}_s(B)}{\hat{\delta}_r(B)} B^b x_t.\end{aligned}$$

- f. Penentuan model ARMA *tentative* untuk n_t

Setelah didapat nilai-nilai n_t , dapat ditentukan model ARMA tetatif yang tepat menjelaskan nilai-nilai n_t tersebut. Misalkan model yang terbentuk adalah ARIMA ($p, 0, q$) maka dapat digunakan model persamaan sebagai berikut :

$$\phi_p(B)n_t = \theta_q(B)a_t,$$

dimana,

$$\phi_p(B) = \text{operator autoregressive orde ke-p dari } n_t$$

$$\theta_q(B) = \text{operator Moving Average orde ke-q dari } n_t$$

$$a_t = \text{residual dari deret } n_t$$

Setelah deret n_t diperoleh dari prosedur di atas, langkah selanjutnya adalah memperoleh nilai dari a_t dengan menggunakan persamaan 2.6 sehingga diperoleh nilai deret a_t sebagai berikut :

$$y_t = v(B)x_t + n_t$$

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} B^b x_t + \frac{\theta_q(B)}{\phi_p(B)} a_t.$$

Tahap 2. Estimasi Parameter

Setelah mengidentifikasi bentuk model fungsi transfer sementara, yaitu :

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t. \quad (2.7)$$

Maka kita perlu mengestimasi parameter $\delta = (\delta_1, \dots, \delta_r)'$, $\omega = (\omega_0, \omega_1, \dots, \omega_r)'$, $\phi = (\phi_1, \dots, \phi_p)$, $\theta = (\theta_1, \dots, \theta_q)'$ dan σ_a^2 sehingga persamaan 2.7 dapat ditulis kembali :

$$\begin{aligned} \delta(B)\phi(B)y_t &= \phi(B)\omega(B)x_{t-b} + \delta(B)\theta(B)a_t \\ c(B)y_t &= d(B)x_{t-b} + e(B)a_t, \end{aligned}$$

dimana

$$\begin{aligned} c(B) &= \delta(B)\phi(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \phi_1 B - \dots - \phi_p B^p) \\ &= (1 - c_1 B - c_2 B^2 - \dots - c_{p+r} B^{p+r}), \\ d(B) &= \phi(B)\omega(B) = (1 - \phi_1 B - \dots - \phi_p B^p)(\omega_0 - \omega_1 B - \dots - \omega_s B^s) \\ &= (d_0 - d_1 B - d_2 B^2 - \dots - d_{p+s} B^{p+s}), \\ e(B) &= \delta(B)\theta(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \theta_1 B - \dots - \theta_q B^q) \\ &= (1 - e_1 B - \dots - e_{r+q} B^{r+q}). \end{aligned}$$

jadi diperoleh

$$\begin{aligned} a_t &= y_t - c_1 y_{t-1} - \dots - c_{p+r} y_{t-p-r} - d_0 x_{t-b} + d_1 x_{t-b-1} \\ &\quad + d_{p+s} x_{t-b-p-s} + e_1 a_{t-1} + \dots + e_{r+q} a_{t-r-q}, \end{aligned}$$

dimana c_i, d_j dan e_k adalah fungsi dari $\delta_i, \omega_j, \phi_k$ dan θ_l . Dibawah asumsi a_t *white Noise* mengikuti distribusi normal $(0, \sigma_a^2)$. Sehingga dapat ditulis fungsi likelihood, yaitu :

$$L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, x, y, x_0, y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} \exp\left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right].$$

Estimasi parameter $\omega, \delta, \phi, \theta$ dan σ_a^2 dapat juga diestimasi dengan menggunakan metode *conditionally least square* dengan mengasumsikan a_t yang tidak diketahui sama dengan nol. Estimasi model fungsi transfer dapat diminimumkan dengan persamaan seperti berikut ini :

$$S((\delta, \omega, \phi, \theta | b) = \sum_{t=t_0}^n a_t^2,$$

dimana $t_0 = \max \{p+r+1, b+p+s+1\}$.

Tahap 3 : Diagnosa Model Fungsi Transfer

Setelah model fungsi transfer dan parameter telah diestimasi, sangat penting untuk mengecek kebaikan model dalam melakukan peramalan. Kita harus mengecek residual a_t dari model *noise* demikian pula dengan residual *input* yang telah melalui proses *prewhitening* (α_t) apakah telah memenuhi asumsi berikut :

1) Pengecekan *Cross-correlation*

Cross-correlation digunakan untuk mengecek apakah deret noise a_t dan deret *input* x_t sudah independen. Untuk model yang baik, maka sampel CCF $\hat{\rho}_{\alpha\hat{a}}(k)$ antara \hat{a}_t dan α_t harus menunjukkan tidak ada yang signifikan. Pendeteksian tersebut dapat menggunakan *portmanteau test*, yaitu:

$$Q_0 = m(m+2) \sum_{j=0}^K (m-j)^{-1} \hat{\rho}_{\alpha\hat{a}}^2(j),$$

dimana Q_0 mengikuti distribusi χ^2 dengan derajat bebas $(K+1) - M$ dimana $m = n - t_0 + 1$ dan M adalah jumlah parameter δ_i dan ω_i yang diestimasi dari model fungsi transfer $v(B) = \omega(B)/\delta(B)$. Jumlah derajat bebas untuk Q_0 adalah independen pada jumlah parameter yang diestimasi dalam model *noise*.

2) Cek *autocorrelation*

Untuk mengecek ketepatan model noise, maka diharapkan baik ACF maupun PACF dari \hat{a}_t tidak ada yang signifikan. Pengecekan tersebut menggunakan model seperti berikut ini:

$$Q_1 = m(m+2) \sum_{j=1}^K (m-j)^{-1} \hat{\rho}_{\hat{a}}^2(j).$$

dengan Q_1 mengikuti distribusi χ^2 dengan derajat bebas $(K - p - q)$ hanya dependen pada jumlah parameter model *noise*.

Tahapan tersebut diatas merupakan pembentukan model fungsi transfer *input* tunggal. Deret input yang lebih dari satu dapat menggunakan prosedur pembentukan model fungsi transfer multi input. Prosedur pembentukan model fungsi transfer multi *input* yaitu :

- a. Nilai (b, r, s) pada masing-masing deret *input* yang telah didapat. Dilakukan secara serempak dengan metode penaksiran yang digunakan adalah *conditional least square estimation*.
- b. Sedangkan nilai estimasi dari gangguan *noise* gabungannya didapat dari rumus

$$\begin{aligned}\hat{n}_t &= y_t - \hat{v}(B)x_t \\ &= y_t - \sum_{j=1}^k \frac{\omega_{s_j}(B)}{\delta_{r_j}(B)} B^{b_j} x_{j,t}.\end{aligned}$$

Estimasi yang dilakukan dalam model fungsi transfer ini menggunakan alat bantu program SAS. Nilai (b, r, s) yang telah diidentifikasi dalam model fungsi transfer *input* tunggal sehingga model fungsi transfer multi *input* menjadi

$$\begin{aligned}y_t &= \sum_{j=1}^K v_j(B)x_{j,t} + n_t \\ &= \sum_{j=1}^K \frac{\omega_{s_j}(B)B^{b_j}}{\delta_{r_j}(B)} x_{j,t} + \frac{\theta_q(B)}{\phi_p(B)} a_t,\end{aligned}$$

dengan,

- y_t = representasi dari deret *output* yang stasioner,
- $v_j(B)$ = $v_{0h} + v_{1h}B + v_{2h}B^2 + \dots$, merupakan koefisien model fungsi transfer atau bobot respon impuls untuk *input series* ke- j ,
- n_t = representasi dari variabel error (*deret noise*) yang mengikuti suatu model ARIMA tertentu,
- $x_{j,t}$ = representasi dari *input* yang stasioner variabel ke- j ,
- $\omega_{s_j}(B)$ = operator dengan orde s , yang mempresentasikan jumlah pengamatan masa lalu x_{ht} yang berpengaruh terhadap y_t untuk variabel yang ke- j ,
- $\delta_{r_j}(B)$ = operator dengan orde r , yang mempresentasikan jumlah pengamatan masa lalu dari deret *output* itu sendiri yang berpengaruh terhadap y_t untuk variabel yang ke- j .

2.5 Model Time Series Multivariat

Analisis *time series* univariat dapat digunakan hanya pada saat satu variabel yang diteliti, namun dalam kenyataanya banyak data time series yang saling berkaitan antara variabel yang satu dengan variabel yang lainnya. Model time series multivariat adalah analisis model time series yang yang baik digunakan dalam memodelkan dan menjelaskan interaksi sejumlah varibel time series yang memiliki keterkaitan pada waktu sebelumnya sehingga model dan peramalan yang diperoleh lebih akurat.

Proses dalam pemodelan multivariat time series sama dengan pemodelan time series univariat, dimana mensyaratkan data time series harus stasioner dalam varians dan rata-rata. Data multivariat yang tidak stasioner dalam varians dapat dilakukan transformasi sedangkan data yang tidak stasioner dalam mean dapat dilakukan *differencing*. Dalam menentukan suatu data multivariat time series telah stasioner dapat dengan melihat plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correktion Function* (MPCCF) serta Box-Cox (Wei, 2006)

2.5.1. Matrix Cross Correlation Function (MCCF)

Jika terdapat sebuah vektor time series dengan pengamatan sebanyak n , yaitu $Y_1, Y_2, Y_3 \dots Y_n$ maka persamaan MCCF dinyatakan dalam bentuk sebagai berikut (Wei, 2006):

$$\hat{\rho}_{ij}(k) = [\hat{\rho}_{ij}(k)],$$

dengan $\hat{\rho}_{ij}(k)$ merupakan korelasi silang sampel untuk komponen series ke- i dan ke- j yang dinyatakan dalam bentuk :

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\left[\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 (Y_{j,t} - \bar{Y}_j)^2 \right]^{1/2}},$$

dimana \bar{Y}_i dan \bar{Y}_j merupakan rata-rata sampel dari komponen series yang bersesuaian.

Persamaan matriks korelasi sampel sangat berguna untuk menentukan orde dalam model *Moving Average* (MA). Akan tetapi bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Tiao dan Box (1981) memperkenalkan sebuah metode yang sesuai untuk meringkas penjelasan korelasi sampel, yaitu dengan menggunakan simbol (+), (-), dan (.) pada posisi baris ke- i dan kolom ke- j dari matriks korelasi sampel. Beberapa aturan dalam pembentukan skema MCCF yaitu:

1. Simbol (+) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang lebih besar dari 2 kali estimasi standar *error* ($\hat{\rho}(k)$) dan menunjukkan adanya hubungan korelasi positif.
2. Simbol (-) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang kurang dari -2 kali estimasi standar *error* ($\hat{\rho}(k)$) atau adanya hubungan korelasi negatif.

3. Simbol (.) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang berada diantara ± 2 kali estimasi standar error ($\hat{\rho}(k)$) yang artinya tidak terdapat hubungan korelasi.

Persamaan estimasi standar error pada aturan di atas dapat didefinisikan sebagai berikut ;

$$se(\hat{\rho}_{(k)}) = \frac{1}{\sqrt{n-k}}$$

Tabel 2.3 Contoh nilai MCCF untuk tiga data *Time Series*

Lag	0			1			2		
Variabel	Y_1	Y_2	Y_3	Y_1	Y_2	Y_3	Y_1	Y_2	Y_3
Y_1	1	0,57	0,69	0,01	0,06	0,21	-0,12	-0,20	-0,09
Y_2	0,57	1	0,66	0,10	0,12	0,11	-0,08	-0,19	-0,09
Y_3	0,69	0,66	1	0,16	0,15	0,19	-0,19	-0,22	-0,14

Pada Tabel 2.3 diberikan hasil perhitungan nilai-nilai MCCF dari tiga data *time series* dengan masing-masing series terdiri dari 132 pengamatan. Dengan batas ± 2 kali estimasi standar error ($\hat{\rho}_k$), nilai MCCF selanjutnya dinotasikan ke dalam bentuk simbol yang ditampilkan seperti pada Tabel 2.4. Data telah dikatakan stasioner jika plot MCCF sedikit atau jarang menampilkan tanda (+) dan (-) dan hampir semua tanda bersimbol (.).

Tabel 2.4 Contoh Plot MCCF untuk Tiga Data *Time Series*

Variabel/	0	1	2
Y1	+++	..+	.-.
Y2	+++-.
Y3	+++	..+	--.

2.5.2. Matrix Partial Cross Correlation Function (MPCCF)

Fungsi autokorelasi parsial (PACF) biasa digunakan pada saat kita ingin menentukan orde p dalam model *autoregressive* (AR(p)) pada data *time series* univariat. Tiao dan Box (1981) mendefinisikan matriks autoregresi parsial pada lag s dengan notasi $\mathcal{P}(s)$ sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *vector autoregressive* (VAR) dari orde s . $\mathcal{P}(s)$ sama dengan $\phi_{s,s}$ dalam regresi multivariat, sehingga persamaan untuk matriks autoregresi parsial dinyatakan dalam bentuk seperti berikut:

$$\mathcal{P}(s) = \begin{cases} \Gamma'(1)[\Gamma(1)]^{-1} & s = 1 \\ \{\Gamma^1(s) - c^1(s)[A(s)]^{-1}b(s)\}\{\Gamma(0) - b'(s)[A(s)]^{-1}b(s)\}, & s > 1 \end{cases}$$

untuk $s \geq 2$ maka nilai $A(s)$, $b(s)$ dan $c(s)$

$$A(s) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \dots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix},$$

$$b(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, \quad c(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}.$$

Jika model dari data merupakan vektor AR (p), maka :

$$\mathcal{P}(s) = \begin{cases} \Phi_p, & s = p \\ 0, & s > p. \end{cases}$$

Sama halnya dengan persamaan parsial pada kasus data univariat, persamaan matriks parsial autoregresi, $\mathcal{P}(s)$ juga memiliki sifat *cut-off* untuk proses vektor AR. Sejalan dengan interpretasi MCCF, Tiao dan Box (1981) juga mengidentifikasi data berdasarkan nilai MPCCF dengan menotasikan nilai-nilai MPCCF dalam bentuk symbol (+), (-) dan (.). Tanda (+) untuk nilai lebih besar dari 2 kali estimasi standar *error* ($\hat{\Phi}_p(k)$), tanda (-) untuk nilai kurang dari 2 kali estimasi standar *error* ($\hat{\Phi}_p(k)$) dan tanda (.) untuk nilai ± 2 kali estimasi standar *error* ($\hat{\Phi}_p(k)$). Bentuk simbol dari nilai MPCCF pada Tabel 2.5 ditampilkan dalam Tabel 2.6.

Tabel 2.5 Contoh nilai MPCCF untuk Tiga Data *Time Series*

Lag Variabel	1			2			3		
	Y_1	Y_2	Y_3	Y_1	Y_2	Y_3	Y_1	Y_2	Y_3
Y_1	-0,18	-0,06	0,28	-0,12	-0,08	0,06	0,02	-0,06	0,05
Y_2	0,07	0,09	-0,03	0,05	0,14	-0,02	0,10	-0,04	-0,10
Y_3	0,15	0,08	0,06	-0,16	-0,11	-0,10	-0,04	-0,02	-0,20

Tabel 2.6 Contoh Plot MPPCF untuk Tiga Data *Time Series*

variabel	0	1	2
Y1	-.+	.+.	...
Y2
Y3-

2.5.3. Akaike's Information Criterion (AIC)

Akaike (1973) memperkenalkan *Akaike's Information Criterion* (AIC) suatu kriteria pemilihan model terbaik dengan mempertimbangkan banyaknya parameter. Kriteria pemilihan model terbaik dengan membandingkan nilai AIC yang terkecil (minimum) diantara model yang diperoleh. Rumus AIC yang digunakan sebagai berikut:

$$AIC(p) = \ln(|S(p)|) + \frac{2pm^2}{n}.$$

Dengan p adalah orde proses VAR($p=1,2,\dots,p_0$) dimana p_0 merupakan bilangan bulat positif, n banyaknya observasi, m adalah banyaknya variabel dan $|S(p)|$ merupakan determinan dari *residual sum of square* dan perkalian silangnya, yaitu

$$S_p = \sum_{t=p+1}^n A_t A_t'$$

dengan :

$$A_t = Y_t - \hat{\tau} - \hat{\Phi}_1 Y_{t-1} - \dots - \hat{\Phi}_p Y_{t-p}$$

dimana $\hat{\tau}$ adalah vektor konstan (Wei, 2006).

2.6 Model Generalized Spaced Time Autoregressive (GSTAR)

Model GSTAR merupakan suatu model yang cenderung fleksibel sebagai generalisasi model STAR dan cenderung lebih spesifik dari model VAR. Pfeifer dan Deutsch (1980a) mengemukakan bahwa model STAR adalah suatu model yang dikategorikan berdasarkan lag yang berpengaruh secara linier baik lokasi dan waktu.

Jika diberikan $Y_{i,t}$ dengan $t=\{1,2,\dots,T\}$ dan $i=\{1,2,\dots,N\}$ sebagai indeks yang menyatakan parameter waktu dan lokasi yang dapat dihitung dan terbatas, maka model *Space Time Autoregressive Moving Average* (STARMA) yaitu sebagai berikut (Pfeifer & Deutsch, 1980b) :

$$Y_t = \sum_{k=1}^p \sum_{l=0}^{\lambda_p} \Phi_{kl} W^l Y_{t-k} - \sum_{k=1}^q \sum_{l=0}^{m_q} \theta_{kl} W^{(l)} Y_{t-k} + \varepsilon_t,$$

dengan

$$\Phi_{kl} \text{ dan } \theta_{kl} = \text{Matriks regresi},$$

$$W^{(l)} = \text{Matriks bobot yang dipengaruhi oleh lokasi},$$

$\boldsymbol{\varepsilon}_t$ = vektor noise komponen error.

Dalam model tersebut Peifer dan Deutsch menyatakan observasi lokasi i pada saat t dengan kombinasi linier dari lokasi tersebut pada saat sebelumnya dan residual pada saat sebelumnya. Apabilan orde $p=0$, maka persamaan sebelumnya menjadi *Space Time Moving Average* (STMA) dan jika $q=0$ maka model *Space Time Autoregressive* (STAR) (Pfeifer & Deutsch, 1980a).

Model STAR orde (p_1) yang berarti orde spasial adalah 1 dan orde waktu adalah p , atau model STAR (p_1) dapat ditulis sebagai berikut :

$$\mathbf{Y}_t = \sum_{k=1}^p [\boldsymbol{\Phi}_{k0} \mathbf{W}^0 \mathbf{Y}_{t-k} + \boldsymbol{\Phi}_{k1} \mathbf{W}^1 \mathbf{Y}_{t-k}] + \boldsymbol{\varepsilon}_t,$$

dengan

$\boldsymbol{\Phi}_{k1}$ = Matriks diagonal parameter STAR pada lag waktu (time) k dan lag spasial 1,

$\mathbf{W}^{(1)}$ = matriks bobot ukuran $(N \times N)$ pada lag spasial (dengan $l=0,1$), dengan $\mathbf{W}^{(0)}$ adalah matriks identitas ukuran $(N \times N)$,

$\boldsymbol{\varepsilon}_t$ = vektor noise ukuran $(N \times 1)$ berdistribusi normal multivariat dengan mean nol dan matriks varian-kovarians $\sigma^2 \mathbf{I}_N$,

\mathbf{Y}_t = vektor acak ukuran $(N \times 1)$ pada waktu t yaitu $\mathbf{Y}(t) = [Y_{1,t}, \dots, Y_{N,t}]'$.

Model STAR (1_1) dengan lokasi sebanyak N dapat dinyatakan sebagai berikut:

$$\mathbf{Y}_t = \phi_{10} \mathbf{I}_N \mathbf{Y}_{t-1} + \phi_{11} \mathbf{I}_N \mathbf{W}^{(1)} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_t, \quad (2.8)$$

persamaan 2.8 untuk 3(tiga) lokasi dapat dijabarkan sebagai berikut:

$$Y_{1,t} = \phi_{10} Y_{1,t-1} + \phi_{11} w_{12} Y_{2,t-1} + \phi_{11} w_{13} Y_{3,t-1} + \varepsilon_{1,t}$$

$$Y_{2,t} = \phi_{10} Y_{2,t-1} + \phi_{11} w_{21} Y_{1,t-1} + \phi_{11} w_{23} Y_{3,t-1} + \varepsilon_{2,t}$$

$$Y_{3,t} = \phi_{10} Y_{3,t-1} + \phi_{11} w_{31} Y_{1,t-1} + \phi_{11} w_{32} Y_{2,t-1} + \varepsilon_{3,t}$$

Penulisan dalam notasi matriks untuk tiga lokasi juga dapat ditulis sebagai berikut:

$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ Y_{3,t} \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{10} & 0 \\ 0 & 0 & \phi_{10} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{11} & 0 \\ 0 & 0 & \phi_{11} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \varepsilon_3(t) \end{bmatrix}.$$

Kelemahan model STAR adalah pada asumsi parameter autoregresi. Model STAR hanya sesuai digunakan pada lokasi yang homogen dan kurang sesuai pada lokasi yang heterogen. Hal ini dikarenakan model STAR mengasumsikan bahwa semua lokasi memiliki parameter autoregresi yang sama. Kelemahan tersebut dapat diatasi dengan menggunakan model GSTAR. Ruchjana (2002) mengembangkan model GSTAR dengan mengasumsikan bahwa parameter setiap lokasi diperbolehkan berbeda, sehingga model GSTAR sesuai digunakan pada lokasi yang heterogen (Borovkova, Lopuhaa, & Ruchjana, 2008).

Jika diketahui data *time series* $\{Y(t) : t = 0, 1, 2, \dots, T ; i = 1, 2, \dots, N\}$ merupakan sebuah *time series* multivariat dari N pengamatan, maka model GSTAR dengan orde waktu $AR(p)$ dan spasial $(\lambda_1, \lambda_2, \dots, \lambda_p)$ ditulis GSTAR $(\lambda_1, \lambda_2, \dots, \lambda_p)$ dapat dinyatakan sebagai berikut.

$$\mathbf{Y}_t = \sum_{k=1}^p \left[\Phi_{k0} \mathbf{Y}_t + \sum_{l=1}^{\lambda_s} \Phi_{kl} \mathbf{W}^{(l)} \mathbf{Y}_{t-k} \right] + \boldsymbol{\varepsilon}_t,$$

dengan

- \mathbf{Y}_t = vektor acak ukuran $(N \times 1)$ pada waktu t yaitu $\mathbf{Y}_t = [Y_{1,t}, \dots, Y_{N,t}]'$,
- Φ_{k0} = $\text{diag}(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(N)})$ merupakan matriks koefisien parameter waktu,
- Φ_{kl} = $\text{diag}(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$ merupakan matriks koefisien parameter spasial,
- $\mathbf{W}^{(l)}$ = nilai matriks pembobot ukuran $(N \times N)$ pada lag spasial ke- l nilai pembobot yang dipilih harus memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{i \neq j} w_{ij}^{(l)} = 1$,
- $\boldsymbol{\varepsilon}_t$ = vektor *error* yang memenuhi asumsi identik, independen dan berdistribusi normal multivariat dengan rata-rata nol dan matriks varians-kovarians $\sigma^2 I_N$.

Sebagai contoh, secara umum model GSTAR pada persamaan dengan orde waktu 1 dan orde spasial 1 pada lokasi yang berbeda atau GSTAR (1_1) dapat ditulis sebagai berikut:

$$\mathbf{Y}_t = \Phi_{10} \mathbf{Y}_{t-1} + \Phi_{11} \mathbf{W} \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_t, \quad (2.9)$$

dari persamaan 2.9 model untuk tiga lokasi yang berbeda dapat dinyatakan sebagai berikut:

$$Y_{1,t} = \phi_{10}Y_{1,t-1} + \phi_{11}w_{12}Y_{2,t-1} + \phi_{11}w_{13}Y_{3,t-1} + \varepsilon_{1,t},$$

$$Y_{2,t} = \phi_{20}Y_{2,t-1} + \phi_{21}w_{21}Y_{1,t-1} + \phi_{21}w_{23}Y_{3,t-1} + \varepsilon_{2,t},$$

$$Y_{3,t} = \phi_{30}Y_{3,t-1} + \phi_{31}w_{31}Y_{1,t-1} + \phi_{31}w_{32}Y_{2,t-1} + \varepsilon_{3,t},$$

Dengan demikian bentuk notasi matriks untuk tiga lokasi yang berbeda seperti pada persamaan di atas dapat dituliskan sebagai berikut:

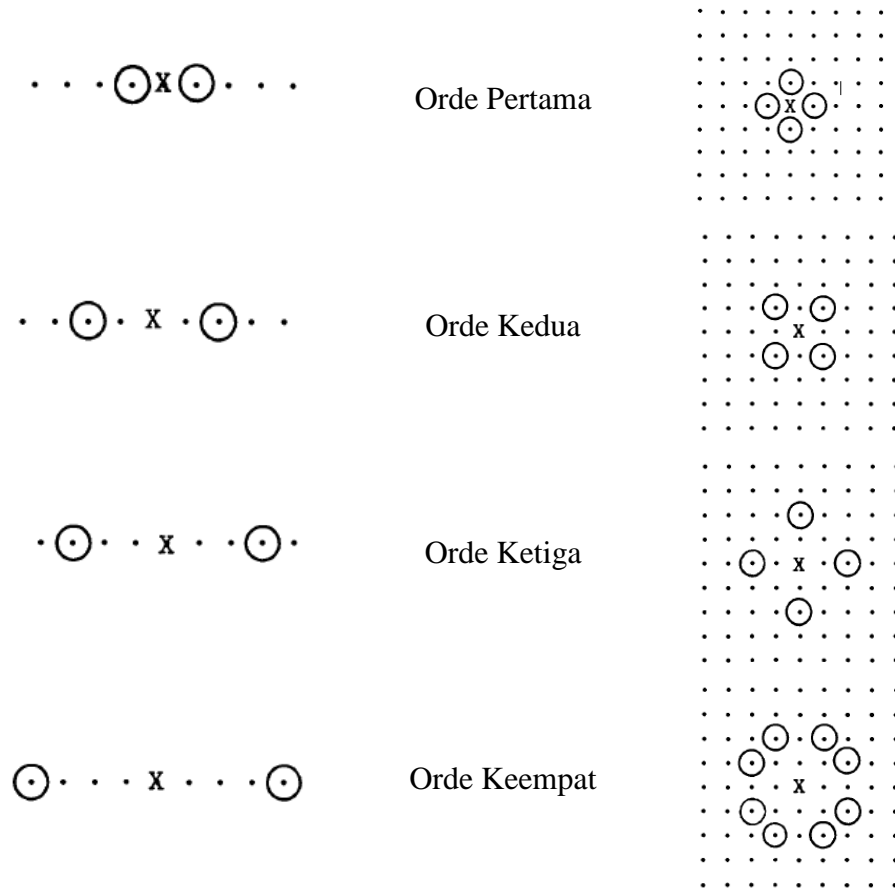
$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ Y_{3,t} \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{20} & 0 \\ 0 & 0 & \phi_{30} \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{21} & 0 \\ 0 & 0 & \phi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12}w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31}w_{32} & 0 & 0 \end{bmatrix} \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

2.6.1. Identifikasi Model pada Model GSTAR

2.6.1.1 Orde Spasial

Karakter model spasial ditandai oleh adanya ketergantungan linier pada lokasi. Tingkat perubahan ketergantungan lokasi dinamakan orde spasial yang dilambangkan dengan l , dengan $l = 1, 2, \dots, \lambda$. Orde spasial merupakan urutan berdasarkan jarak dari suatu lokasi tertentu ke semua lokasi yang ada disekitarnya. Orde pertama adalah lokasi yang paling dekat dengan lokasi yang sedang diteliti, orde kedua adalah lokasi yang lebih jauh dari orde pertama dan lebih dekat dibanding dengan orde ketiga. Orde spasial pada sistem yang teratur digambarkan sebagai perubahan posisi suatu lokasi tertentu digeser ke lokasi terdekat disekitarnya dengan jarak yang sama. Pada sistem yang teratur, orde spasial adalah sistem *lattice* berupa grid bujur sangkar atau lingkaran dengan diameter tertentu.

Pada sistem dua dimensi pergeseran lokasi dapat ke arah kanan atau kiri (barat-timur) dan ke arah atas bawah atau bahwa (utara-selatan). Suatu kriteria yang biasa dipakai dalam sistem *grid* adalah pergeseran lokasi dilakukan hanya satu kali ke lokasi terdekat dengan jarak yang sama untuk setiap orde spasial. Selain itu dapat dipilih jarak minimum yang dicapai dari suatu lokasi tertentu ke lokasi terdekat disekitarnya (Ruchjana, 2002). Sebagai ilustrasi diberikan contoh orde spasial pada sistem satu dimensi dan dua dimensi seperti pada Gambar 2.1 (Pfeifer & Deutsch, 1980a).



Gambar 2.1 Orde Spasial pada satu dan dua dimensi

Orde spasial $l = 0$ menyatakan bahwa suatu lokasi tidak mempunyai tetangga, melainkan lokasinya sendiri. Sedangkan orde spasial $l = 1$ menyatakan paling sedikit terdapat 4 tetangga yaitu 2 tetangga kanan-kiri dan 2 tetangga atas-bawah. Semua perbedaan posisi atau jarak suatu lokasi dengan lokasi yang lainnya pada saat orde spasial 1 dijadikan satu dan diberikan suatu bobot tertentu dan begitu pula untuk orde spasial yang lebih tinggi. Secara umum jika $y_i(t)$ adalah suatu pengamatan pada lokasi ke- i dengan $i=1,2,\dots,N$ dan tetangga terdekatnya pada lokasi ke- j dengan $j=1,2,\dots,N$ serta misalnya $L^{(l)}$ menyatakan operator orde spasial l , maka orde spasial l dapat didefinisikan dengan (Ruchjana, 2002):

$$L^{(0)}Y_{i,t} = Y_{i,t} \text{ untuk } l = 0$$

$$L^{(l)}Y_{i,t} = \sum_{j=1}^N w_{ij}^{(l)} Y_{i,t} \text{ untuk } l \neq 0,$$

dimana $w_{ij}^{(l)}$ adalah suatu bobot tertentu yang menyatakan perbedaan posisi lokasi yang terdekat dari lokasi asal pada orde spasial l .

Identifikasi orde spasial model GSTAR pada umumnya dibatasi pada orde satu karena orde yang tinggi akan sulit untuk dilakukan interpretasi (Wutsqa & Suhartono, 2010). Oleh karena itu, operator orde spasial 1 dalam penelitian ini dinyatakan dengan formula (Ruchjana, 2002):

$$LY_{i,t} = \sum_{j=1}^N w_{ij} Y_{j,t}.$$

Sifat-sifat bobot w_{ij} adalah $w_{ij} > 0$, jika lokasi ke- i dan lokasi ke- j berada dalam orde spasial 1 maka $w_{ij} \neq 0$. Jika lokasi ke- i dan lokasi ke- j tidak berada dalam orde spasial 1 maka $w_{ij} = 0$, jumlah bobot untuk setiap lokasi i adalah $\sum_{j=1}^N w_{ij}^{(l)} = 1$ dan jumlah bobot untuk semua lokasi adalah $\sum_{i=1}^N \sum_{j=1}^N w_{ij}^{(l)} = N$.

Jika \mathbf{Y}_t menyatakan vektor kolom ukuran $(N \times l)$ dari pengamatan $y_{i,t}$ dengan $i = 1, 2, 3, \dots, N$ maka operator orde spasial dinyatakan :

$$L^{(0)}\mathbf{Y}_t = \mathbf{W}^{(0)}\mathbf{Y}_t = \mathbf{I}_N\mathbf{Y}_t \text{ untuk } l = 0$$

$$L^{(l)}\mathbf{Y}_t = \mathbf{W}^{(l)}\mathbf{Y}_t, \text{ untuk } l \neq 0,$$

operator orde spasial 1 dapat dinyatakan dalam bentuk vektor cukup dinyatakan dalam bentuk sederhana sebagai berikut:

$$LY_t = \mathbf{W}\mathbf{Y}_t,$$

selanjutnya dalam bentuk matriks, bobot w_{ij} pada orde spasial 1 dinyatakan oleh \mathbf{W} berupa bujur sangkar $(N \times N)$ sebagai berikut:

$$\mathbf{W} = \begin{bmatrix} 0 & w_{12} & \dots & w_{1N} \\ w_{21} & 0 & \dots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \dots & 0 \end{bmatrix}$$


2.6.1.2 Orde Waktu

Nilai AIC dapat digunakan sebagai penentu orde waktu dalam pembentukan model GSTAR maupun VARMA. Penentuan orde dapat dilakukan dengan menggunakan nilai AIC minimum (Wei, 2006). Akan tetapi penentuan orde model berdasarkan nilai AIC tidak dapat menangkap pola *seasonal*. Oleh

karena itu penentuan orde waktu dapat dilakukan berdasarkan plot MCCF dan MPCCF yang terbentuk (Wutsqa & Suhartono, 2010).

2.6.2. Pemilihan Bobot Lokasi pada Model GSTAR

Pemilihan atau penentuan bobot lokasi merupakan salah satu permasalahan dalam pemodelan GSTAR. Menurut Suhartono dan Subanar (2006), ada beberapa metode yang digunakan dalam pembobotan model GSTAR, yaitu bobot seraga (uniform), biner (binary), *invers* jarak, normalisasi korelasi silang dan normalisasi inferensia korelasi silang. Misalkan diketahui tiga buah lokasi, yaitu A, B, dan C seperti pada Gambar 2.2.



Gambar 2.2 Contoh Hubungan Tiga Lokasi

2.6.2.1 Bobot Seragam

Bobot seragam memberikan nilai bobot yang sama untuk setiap lokasi penelitian. Bobot seragam digunakan pada data dengan lokasi homogen atau memiliki jarak antar lokasi yang sama. Hubungan antar lokasi dianggap dua arah. Rumus dari bobot lokasi seragam $w_{ij} = \frac{1}{n_i}$ dengan n_i adalah jumlah lokasi yang berdekatan dengan lokasi ke- i . Contoh matriks bobot untuk tiga lokasi yang berbeda dapat ditulis sebagai berikut:

$$\mathbf{W} = \begin{bmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{bmatrix}$$

2.6.2.2 Bobot Biner (*Binary*)

Nilai bobot lokasi biner didefinisikan berdasarkan hubungan letak suatu lokasi dengan lokasi lainnya. Hubungan antar dua kota yang secara geografis berdekatan didefinisikan $w_{ij} = 1$. Sedangkan jika secara geografis berjauhan,

maka didefinisikan $w_{ij} = 0$. Nilai tersebut dipakai tergantung pada suatu batasan tertentu.

$$\mathbf{W} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

2.6.2.3 Bobot *Invers* Jarak

Penentuan bobot *invers* jarak dilakukan berdasarkan jarak sebenarnya antar lokasi dilapangan. Penghitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Agar lebih mudah memahami, dimisalkan terdapat tiga lokasi. Pada contoh dengan tiga lokasi dimisalkan diketahui jarak lokasi seperti pada pada Tabel 2.7 berikut:

Tabel 2.7 Contoh Jarak dari Tiga Lokasi

Lokasi	Lokasi		
	Kota A	Kota B	Kota C
Kota A	0	$d_{AB} = 1$	$d_{AC} = 2$
Kota B	$d_{BA} = 1$	0	$d_{BC} = 3$
Kota C	$d_{BC} = 1$	$d_{CB} = 1$	0

Bentuk matrik jarak yang terbentuk adalah :

$$D = \begin{bmatrix} d_{AA} & d_{AB} & d_{AC} \\ d_{BA} & d_{BB} & d_{BC} \\ d_{CA} & d_{CB} & d_{CC} \end{bmatrix}.$$

Kemudian matriks \mathbf{D} tersebut distandarkan dalam bentuk \mathbf{W} untuk memenuhi sifat bobot $\sum_{j=1}^N w_{ij}^{(l)} = 1$, $j \neq i$. Asumsi yang digunakan yaitu lokasi dengan jarak yang dekat memiliki hubungan antar lokasi yang kuat maka secara umum bobot *invers* jarak untuk masing-masing lokai dapat dinyatakan sebagai berikut:

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^n \frac{1}{d_{ij}}}, j \neq i,$$

dengan jumlah bobot untuk setiap lokasi adalah 1, $\sum_{j=1}^N w_{ij}^{(l)} = 1$ dan $\sum_{i=1}^N \sum_{j=1}^N w_{ij} = N$. Diagonal matriks *invers* jarak w_{ij} adalah nol, karena untuk suatu lokasi tidak ada jarak dengan dirinya sendiri, secara umum bentuk *invers* jarak adalah :

$$\mathbf{W} = \begin{bmatrix} 0 & \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} & \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} \\ \frac{\frac{1}{d_{BA}}}{\frac{1}{d_{BA}} + \frac{1}{d_{BC}}} & 0 & \frac{\frac{1}{d_{BC}}}{\frac{1}{d_{BA}} + \frac{1}{d_{BC}}} \\ \frac{\frac{1}{d_{CA}}}{\frac{1}{d_{CA}} + \frac{1}{d_{CB}}} & \frac{\frac{1}{d_{CB}}}{\frac{1}{d_{CA}} + \frac{1}{d_{CB}}} & 0 \end{bmatrix}.$$

Contoh perhitungan bobot invers jarak berdasarkan ilustrasi jarak lokasi tiga kota adalah sebagai berikut:

$$W_{AB} = \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} = \frac{1}{1 + \frac{1}{2}} = \frac{2}{3}, \quad W_{AC} = \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} = \frac{\frac{1}{2}}{1 + \frac{1}{2}} = \frac{1}{3},$$

dengan cara yang sama akan diperoleh,

$$W_{BA} = \frac{3}{4}, W_{BC} = \frac{1}{4}, W_{CA} = \frac{3}{5}, W_{CB} = \frac{2}{5}.$$

Sehingga dengan metode invers jarak dalam bentuk matriks pembobot dapat ditulis sebagai berikut :

$$\mathbf{W} = \begin{bmatrix} 0 & 2/3 & 1/3 \\ 3/4 & 0 & 1/4 \\ 3/5 & 2/5 & 0 \end{bmatrix}.$$

Bentuk bobot invers jarak W bukan merupakan matriks simetris, karena matriks jarak D setelah distandarkan pada setiap lokasi harus memenuhi sifat bobot $\sum_{j=1}^N w_{ij} = 1, j \neq i$, kecuali untuk masing-masing lokasi mempunyai jarak yang sama.

2.6.2.4 Bobot Normalisasi Korelasi Silang

Penentuan nilai bobot normalisasi korelasi silang dilakukan dengan menggunakan hasil normalisasi korelasi silang antar lokasi pada lag yang bersesuaian. Suhartono dan Subanar (2006) kemudian mengembangkan penggunaan bobot ini dengan menggunakan inferensia statistik terhadap korelasi silang untuk penentuan bobot lokasinya. Secara umum korelasi silang antar lokasi ke- i dan ke- j pada lag waktu ke- k , $\text{corr}[Y_i(t), Y_j(t - k)]$ dapat dinyatakan sebagai berikut:

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 0, +1, +2 \dots$$

dengan $\gamma_{ij}(k)$ merupakan kovarians antar pengamatan dilokasi ke- i dan ke- j , σ_i dan σ_j merupakan standar deviasi antar pengamatan di lokasi ke- i dan ke- j . taksiran dari korelasi silang pada sampel dapat dinyatakan secara umum, yaitu :

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Y_{i,t} - \bar{Y}_i][Y_{j,t-k} - \bar{Y}_j]}{\sqrt{\sum_{t=1}^n [Y_{i,t} - \bar{Y}_i]^2 [Y_{j,t} - \bar{Y}_j]^2}}. \quad (2.10)$$

Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR (1₁) seperti pada persamaan dibawah ini ;

$$w_{ij} = \frac{r_{ij}(i)}{\sum_{k=1}^n [r_{ij}(i)]} \text{ dengan } j \neq i \text{ dan } \sum_{k=1}^n |w_{ij}| = 1$$

2.6.2.5 Bobot Normalisasi Inferensia Parsial Korelasi Silang

Perhitungan bobot normalisasi inferensia parsial korelasi silang tidak jauh berbeda dengan pembobot normalisasi korelasi silang. Secara umum korelasi silang antar kejadian dilokasi ke- i dan ke- j pada *lag* waktu ke- k . Estimasi persamaan korelasi silang data sampel dapat dilihat pada persamaan korelasi silang data sampel pada persamaan 2.10. Bartlett (1955) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Hipotesis awal menyatakan bahwa dua data *time series* Y_i dan Y_j adalah tidak berkorelasi, seperti yang ditunjukkan pada persamaan berikut ini.

$$\text{Varians } [r_{ij}(k)] \cong \frac{1}{n-k} [1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s)].$$

Sehingga, ketika Y_i dan Y_j merupakan deret *white noise* maka diperoleh persamaan:

$$\text{Varians } [r_{ij}(k)] \cong \frac{1}{n-k}. \quad (2.11)$$

Sedemikian sehingga ketika pada sampel besar ($n - k$) dalam persamaan 2.11 sering kali diganti dengan n . Dibawah asumsi distribusi normal, maka nilai-nilai korelasi silang pada sampel ini dapat diuji apakah sama atau berbeda dengan nol. Uji hipotesis atau proses inferensia statistik dapat dilakukan dengan menggunakan taksiran interval, yaitu :

$$r_{ij}(k) \pm [t_{(\frac{\alpha}{2}, n-k-2)}, \frac{1}{\sqrt{n}}].$$

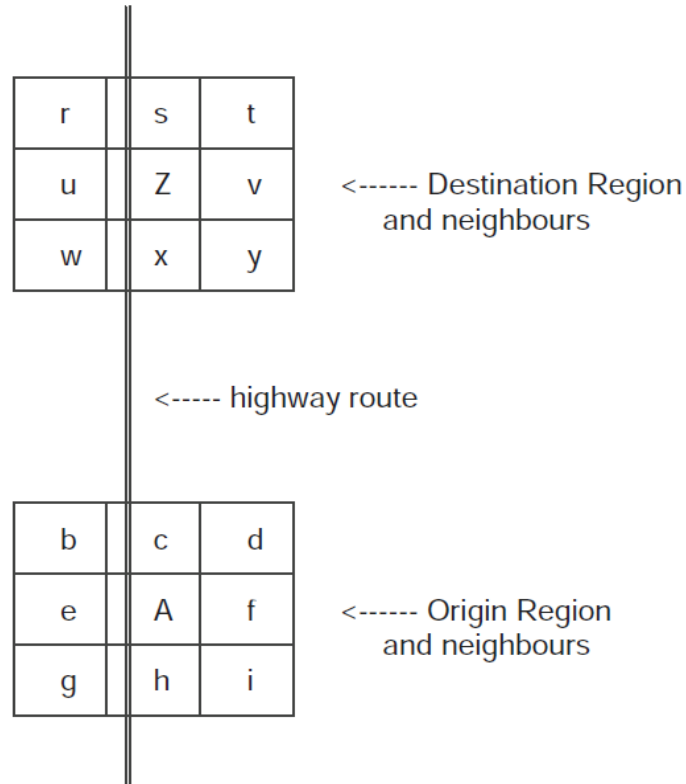
Proses ini secara umum dapat menghasilkan bobot lokasi dengan menggunakan normalisasi dari hasil inferensia statistik parsial terhadap korelasi silang antar lokasi pada lag waktu yang bersesuaian. Bobot lokasi ini memberikan beberapa keuntungan yaitu, [1] memungkinkan semua bentuk kemungkinan hubungan antar lokasi dengan demikian tidak ada lagi batasan yang kaku tentang besarnya bobot terutama yang bergantung dari jarak antar lokasi, [2] bobot ini memberikan fleksibilitas pada besaran dan tanda hubungan antar lokasi yang berlainan (positif dan negatif) [3] bobot ini telah mencakup bobot lokasi seragam dan biner (Suhartono & Subanar, 2006).

2.6.2.6 Matriks Bobot Spatial Konektifitas

Model spatial ekonometrik telah mengikutsertakan konsep ketergantungan antar wilayah yang direpresentasikan dalam matriks bobot spatial. *Gravity Model* dan *Spatial Interaction Model* merupakan contoh model spatial ekonometrik yang telah banyak digunakan pada berbagai literatur untuk menjelaskan sebuah model yang fokus pada arus komoditas dari wilayah penghasil (*origin*) ke wilayah tujuan (*destination*) (Sen dan Smith (1995) dalam Lesage (2005)). Gagasan utamanya yaitu, interaksi antar wilayah *origin* dan *destination* akan mempengaruhi daerah sekitarnya, namun dalam skala parameter yang kecil. Keterbatasan konektifitas antar wilayah dipengaruhi oleh adanya keterbatasan akses konektifitas antar wilayah.

Meminjam analogi tersebut, maka dalam mengukur ketergantungan antar wilayah dalam konsep arus perdagangan yang dipengaruhi oleh konektifitas transport perlu mengikutsertakan faktor kemudahan akses transportasi dalam matriks pembobot spatial. Awalnya nilai matriks pembobot spatial (w_{ij}) bernilai satu untuk wilayah yang saling bersinggungan dan bernilai nol untuk yang tidak bersinggungan. Namun, dengan adanya keterbatasan akses dari masing-masing wilayah yang berdekatan maka bobot spatial yang digunakan perlu dimodifikasi. Lesage dan Polasek (2008) melakukan pengembangan matriks bobot spatial yang digunakan dengan pertimbangan, wilayah yang memiliki akses transportasi mudah berupa adanya jalan bebas hambatan, jalur kereta api sistem pengapalan

(*shipment*) cenderung memiliki perdagangan yang lebih maju. Berikut contoh ilustrasi :




Gambar 2.3 Hubungan kedekatan antara wilayah *origin-destination*
(Sumber : Lesage dan Polasek, 2008)

Pada Gambar 2.3 mengilustrasikan jalur perdagangan dari daerah penghasil (*Origin*) ke daerah tujuan (*Destination*). Misalkan wilayah h, A, c, x, Z, s merupakan wilayah yang dilalui oleh jalur bebas hambatan, sedangkan wilayah yang lainnya meskipun bertetangga tetapi memiliki keterbatasan akses tersebut. Maka pada kasus ini, perlu dilakukan pembobotan ulang pada matriks bobot spasial dengan mempertimbangkan kemudahan akses tersebut. Sehingga, nilai matriks pembobot hanya terisi pada wilayah yang dilalui oleh jalur bebas hambatan yang berupa jumlah pintu masuk dan pintu keluar dari masing-masing wilayah yang saling berinteraksi.

Pada penelitian ini diberikan suatu gagasan konektifitas antar wilayah yang diwakili oleh berapa jumlah moda transportasi yang menghubungkan antar daerah. Moda transportasi laut yang dimaksud lebih khusus adalah moda

transporlasi laut (Kapal Pelni). Berikut bobot spasial konektivitas antara tiga wilayah di Pulau Papua.



Gambar 2.4 Contoh Matriks Bobot Spasial Konektivitas

2.7 Estimasi Parameter pada Model GSTAR

Estimasi parameter yang digunakan dalam model GSTAR berikut terdiri dari metode estimasi *Ordinary Least Square* (OLS) dan metode estimasi *Generalized Least Square* (GLS). Estimasi parameter GSTAR pada penelitian ini menggunakan GLS.

2.7.1. Metode Estimasi *Ordinary Least Square* (OLS)

Penaksiran parameter pada model GSTAR sama dengan menaksir parameter pada regresi klasik yaitu dengan meminimumkan jumlah kuadrat simpanganya (Ruchjana, 2002). Dengan mengambil orde autoregresi $p=1$ dan orde spasial $\lambda_p = 1$ maka persamaan model GSTAR (1₁) juga dapat dinyatakan sebagai berikut

$$\mathbf{Y}_t = \Phi_{10} \mathbf{Y}_{t-1} + \Phi_{11} \mathbf{W}^1 \mathbf{Y}_{t-1} + \boldsymbol{\varepsilon}_t,$$

dengan Φ_{10} sebagai parameter autoregresi untuk keterkaitan waktu, Φ_{11} sebagai parameter regresi spasial dan \mathbf{W} merupakan matriks pembobot.

Dikarenakan metode *least square* sering digunakan sebagai penaksir parameter pada model linier, sehingga metode ini dapat diterapkan pada model GSTAR (1₁) yang dapat ditulis dalam bentuk linier sebagai berikut :

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2.12)$$

atau dalam bentuk matriks dapat ditulis sebagai berikut :

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_N \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} \mathbf{X}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{X}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{X}_N \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_N \end{bmatrix}, \quad \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_N \end{bmatrix}$$

Persamaan diatas dapat dimodifikasi sehingga terdapat beberapa lokasi seperti pada model GSTAR, sehingga persamaan 2.12 dapat ditulis kembali untuk lokasi ke- i yaitu :

$$Y_i = X_i \beta_i + \varepsilon_i$$

dengan $Y_i(t)$ merupakan banyaknya pengamatan ke- t ($t = 0, 1, \dots, T$) untuk lokasi ke- i ($i = 1, 2, \dots, N$) dan $\beta_i = (\phi_{i0}^1, \phi_{i1}^1)$. Jika diketahui $V_i(t) = \sum_{j \neq i} w_{ij} Y_j(t)$ maka persamaan 2.60 dapat dijabarkan dalam bentuk matrik sebagai berikut :

$$\mathbf{Y}_i = \begin{bmatrix} Y_{1,1} \\ Y_{2,2} \\ \vdots \\ Y_{N,T} \end{bmatrix}, \quad \mathbf{X}_i = \begin{bmatrix} Y_{i,0} & V_{i,0} \\ Y_{i,1} & V_{i,1} \\ \vdots & \vdots \\ Y_{i,t-1} & V_{i,t-1} \end{bmatrix}, \quad \beta_i = \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix}, \quad \varepsilon_i = \begin{bmatrix} \varepsilon_{i,1} \\ \varepsilon_{i,2} \\ \vdots \\ \varepsilon_{i,N} \end{bmatrix}$$

Jika $\beta_i = (\phi_{10}^1, \phi_{11}^1, \phi_{20}^1, \phi_{21}^1, \dots, \phi_{N0}^1, \phi_{N1}^1)$, penjabaran matriks yang lebih rinci didapatkan pada persamaan matriks berikut:

$$\begin{bmatrix} Y_{1,1} \\ Y_{1,2} \\ \vdots \\ Y_{1,T} \\ \vdots \\ Y_{N,1} \\ Y_{N,2} \\ \vdots \\ Y_{N,T} \end{bmatrix} = \begin{bmatrix} Y_{1,0} & V_{1,0} & \dots & 0 & 0 \\ Y_{1,1} & V_{1,1} & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Y_{1,T-1} & V_{1,T-1} & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & Y_{N,0} & V_{1,0} \\ 0 & 0 & \dots & Y_{N,1} & V_{1,1} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & Y_{N,T-1} & V_{1,T-1} \end{bmatrix} \begin{bmatrix} \phi_{10}^1 \\ \phi_{11}^1 \\ \vdots \\ \phi_{N0}^1 \\ \phi_{N1}^1 \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,1} \\ \varepsilon_{1,2} \\ \vdots \\ \varepsilon_{1,T} \\ \vdots \\ \varepsilon_{N,1} \\ \varepsilon_{N,2} \\ \vdots \\ \varepsilon_{N,T} \end{bmatrix}$$

Estimator *least square* untuk β_i dapat dihitung terpisah pada masing-masing lokasi namun tetap bergantung pada nilai Y_t dilokasi yang lain. Contoh struktur data untuk estimasi parameter model GSTAR (1_1) di tiga lokasi berbeda dapat dituliskan sebagai berikut :

$$Y_{1,t} = \phi_{10} Y_{1,t-1} + \phi_{11} w_{12} Y_{2,t-1} + \phi_{11} w_{13} Y_{3,t-1} + \varepsilon_{1,t-1},$$

$$Y_{2,t} = \phi_{10} Y_{2,t-1} + \phi_{11} w_{21} Y_{1,t-1} + \phi_{11} w_{23} Y_{3,t-1} + \varepsilon_{2,t-1},$$

$$Y_{3,t} = \phi_{10} Y_{3,t-1} + \phi_{11} w_{31} Y_{1,t-1} + \phi_{11} w_{32} Y_{2,t-1} + \varepsilon_{3,t-1}.$$

Jika $V_{i,t-1} = \sum_{j \neq i} w_{ij} Y_{j,t-1}$ maka model diatas dapat dibentuk dalam notasi matriks sebagai berikut:

$$\begin{bmatrix} Y_{1,t} \\ Y_{2,t} \\ Y_{3,t} \end{bmatrix} = \begin{bmatrix} Y_{1,t-1} & 0 & 0 & V_{1,t-1} & 0 & 0 \\ 0 & Y_{2,t-1} & 0 & 0 & V_{2,t-1} & 0 \\ 0 & 0 & Y_{3,t-1} & 0 & 0 & V_{3,t-1} \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{20} \\ \phi_{30} \\ \phi_{11} \\ \phi_{21} \\ \phi_{31} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Estimasi terhadap parameter β dengan cara meminimumkan fungsi:

$$\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}).$$

Sehingga menghasilkan estimator $\hat{\beta}$ dilakukan dengan menggunakan metode *least square* sebagai berikut:

$$\hat{\beta} = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{Y}.$$

Khususnya untuk vektor parameter ϕ_{10} dan ϕ_{11} dengan $i = 1, 2, \dots, N$

$$\begin{bmatrix} \phi_{10} \\ \phi_{11} \end{bmatrix} = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{Y}_i.$$

2.7.2. Estimasi Parameter dengan *Generalized Least Square* (GLS)

Jika suatu model data *time series* memiliki residual yang berkorelasi antar persamaan maka perbaikan estimasi parameter model dapat menggunakan model *Seemingly Unrelated Regression* (SUR). Zellner (1962) memperkenalkan suatu pemodelan beberapa persamaan regresi dengan residual antar persamaan satu dengan persamaan yang lainnya saling berautokorelasi. Menurut Greene (2007) GLS dapat digunakan untuk mengestimasi parameter pada model SUR. Model SUR dengan N persamaan dimana masing-masing persamaan terdiri dari K variable prediktor dapat dinyatakan sebagai berikut :

$$\begin{aligned} Y_1 &= \beta_{10} + \beta_{11}X_{1,1} + \beta_{12}X_{1,2} + \dots + \beta_{1k}X_{1,k} + \varepsilon_1, \\ Y_2 &= \beta_{20} + \beta_{21}X_{2,1} + \beta_{22}X_{2,2} + \dots + \beta_{2k}X_{2,k} + \varepsilon_2, \\ &\vdots \\ Y_N &= \beta_{N0} + \beta_{N1}X_{N,1} + \beta_{N2}X_{N,2} + \dots + \beta_{Nk}X_{N,k} + \varepsilon_N. \end{aligned} \tag{2.13}$$

dengan $i=1, 2, \dots, N$ dimana N menyatakan banyaknya persamaan dalam sistem. Model SUR pada persamaan 2.13 dapat ditulis dalam bentuk matriks sebagai berikut:

$$\begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_N \end{bmatrix} = \begin{bmatrix} \mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}_N \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_N \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_N \end{bmatrix}. \quad (2.14)$$

Secara umum persamaan matriks 2.14 dapat ditulis pada persamaan 2.15.

$$\mathbf{Y}_i = \mathbf{X}_i \beta_i + \epsilon_i. \quad (2.15)$$

Jika diberikan $t = 1, 2, \dots, T$ dengan T merupakan banyaknya pengamatan pada data *time series*, maka $\mathbf{Y}_{i,t}$ merupakan vektor respon berukuran $(T \times 1)$, \mathbf{X}_i merupakan matriks variable independen berukuran $(T \times K)$. β_i merupakan vektor parameter berukuran $(K \times 1)$, dan ϵ_i merupakan vektor residual berukuran $(T \times 1)$. Sehingga persamaan 2.15 dapat dituliskan seperti matriks berikut ini :

$$\begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1T} \\ Y_{21} \\ Y_{22} \\ \vdots \\ Y_{2T} \\ \vdots \\ Y_{N1} \\ Y_{N2} \\ \vdots \\ Y_{NT} \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} 1x_{11,1} & x_{11,2} & \dots & x_{11,K} \\ 1x_{12,1} & x_{12,2} & \dots & x_{12,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1x_{1T,1} & x_{1T,2} & \dots & x_{1T,K} \end{bmatrix} & 0 & \dots & 0 \\ & \begin{bmatrix} 1x_{21,1} & x_{21,2} & \dots & x_{21,K} \\ 1x_{22,1} & x_{22,2} & \dots & x_{22,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1x_{2T,1} & x_{2T,2} & \dots & x_{2T,K} \end{bmatrix} & \dots & 0 \\ & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \begin{bmatrix} 1x_{N1,1} & x_{N1,2} & \dots & x_{N1,K} \\ 1x_{N2,1} & x_{N2,2} & \dots & x_{N2,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1x_{NT,1} & x_{NT,2} & \dots & x_{NT,K} \end{bmatrix} \end{bmatrix} \begin{bmatrix} \beta_{10} \\ \beta_{11} \\ \vdots \\ \beta_{1K} \\ \beta_{20} \\ \beta_{21} \\ \vdots \\ \beta_{2K} \\ \vdots \\ \beta_{N0} \\ \beta_{N1} \\ \vdots \\ \beta_{NK} \end{bmatrix} + \begin{bmatrix} \epsilon_{11} \\ \epsilon_{12} \\ \vdots \\ \epsilon_{1T} \\ \epsilon_{21} \\ \epsilon_{22} \\ \vdots \\ \epsilon_{2T} \\ \vdots \\ \epsilon_{N1} \\ \epsilon_{N2} \\ \vdots \\ \epsilon_{NT} \end{bmatrix}.$$

Asumsi yang harus dipenuhi dalam persamaan model SUR adalah $E(\epsilon) = 0$ dan $E(\epsilon'\epsilon) = \sigma_{ij}\mathbf{I}_T$ (Srivastava & Dwivedi, 1979). Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR dapat dinyatakan :

$$E(\epsilon'\epsilon) = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_N \end{bmatrix} [\epsilon_1 \quad \epsilon_2 \quad \dots \quad \epsilon_N]. \quad (2.16)$$

Persamaan 2.16 apabila diuraikan menjadi

$$E(\epsilon'\epsilon) = \begin{bmatrix} E(\epsilon_1\epsilon_1) & E(\epsilon_1\epsilon_2) & \dots & E(\epsilon_1\epsilon_N) \\ E(\epsilon_2\epsilon_1) & E(\epsilon_2\epsilon_2) & \dots & E(\epsilon_2\epsilon_N) \\ \vdots & \vdots & \ddots & \vdots \\ E(\epsilon_N\epsilon_1) & E(\epsilon_N\epsilon_2) & \dots & E(\epsilon_N\epsilon_N) \end{bmatrix}.$$

Karena $E(\varepsilon'\varepsilon) = \sigma_{ij}I_T$ sehingga dapat dituliskan :

$$E(\varepsilon'\varepsilon) = \begin{bmatrix} \sigma_{11}I_T & \sigma_{12}I_T & \cdots & \sigma_{1N}I_T \\ \sigma_{21}I_T & \sigma_{22}I_T & \cdots & \sigma_{2N}I_T \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1}I_T & \sigma_{N2}I_T & \cdots & \sigma_{NN}I_T \end{bmatrix}. \quad (2.17)$$

Persamaan 2.17 apabila diuraikan dengan perkalian Kronecker (\otimes) menjadi

$$\begin{aligned} E(\varepsilon'\varepsilon) &= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_{NN} \end{bmatrix} \otimes \mathbf{I} \\ &= \mathbf{\Sigma} \otimes \mathbf{I} \\ &= \mathbf{\Omega} \end{aligned} \quad (2.18)$$

$$\text{dengan } \mathbf{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_{NN} \end{bmatrix} \text{ dan } \mathbf{I} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix},$$

matriks $\mathbf{\Sigma}$ merupakan matriks *varians-kovarians error* berukuran $(N \times N)$ dan \mathbf{I} merupakan matriks identitas berukuran $(T \times T)$.

Estimasi parameter model SUR dengan Metode GLS memerlukan invers dari matriks varian kovarian residual, dari persamaan 2.18 diperoleh

$$\mathbf{\Omega} = \mathbf{\Sigma} \otimes \mathbf{I},$$

menjadi

$$\mathbf{\Omega}^{-1} = \mathbf{\Sigma}^{-1} \otimes \mathbf{I}.$$

Sehingga diperoleh penaksir tak bias β dengan menggunakan GLS yaitu:

$\hat{\beta} = (\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}\mathbf{\Omega}^{-1}\mathbf{Y}$ karena Karena $\mathbf{\Omega} = \mathbf{\Sigma} \otimes \mathbf{I}$, maka estimator $\hat{\beta}$ adalah sebagai berikut:

$$\hat{\beta} = (\mathbf{X}'(\mathbf{\Sigma} \otimes \mathbf{I})^{-1}\mathbf{X})^{-1}\mathbf{X}'(\mathbf{\Sigma} \otimes \mathbf{I})^{-1}\mathbf{Y} \text{ atau } \hat{\beta} = (\mathbf{X}'\mathbf{\Sigma}^{-1} \otimes \mathbf{I}\mathbf{X})^{-1}\mathbf{X}'\mathbf{\Sigma}^{-1} \otimes \mathbf{I}\mathbf{Y}$$

2.7.3. Regresi dengan Residual Berkorelasi

Penaksiran parameter dengan metode OLS pada analisis regresi menghasilkan penaksir yang bersifat *unbiased* dan konsisten. Namun, apabila

terjadi adanya residual yang berkorelasi antar persamaan dapat menyebabkan hasil estimasi $\hat{\beta}$ dengan metode OLS menjadi tidak konsisten meskipun tetap *unbiased* (Wei, 2006). Terdapat dua tahap dalam mengestimasi parameter apabila terjadi korelasi residual antar persamaan, yaitu:

1. Tahapan pertama adalah sebagai berikut:
 - a. Mempersiapkan deret *input* dan *output* pada masing-masing lokasi yang telah stasioner. Melakukan *pre-whitening* masing-masing deret *input* dan *output* pada setiap lokasi sehingga orde fungsi transfer dapat diperoleh.
 - b. Melakukan pemodelan fungsi transfer seperti yang dilakukan pada sub bab sebelumnya.
 - c. Menghitung deret *noise* $\hat{n}_{i,t}$.
2. Tahapan kedua adalah sebagai berikut:
 - a. Memodelkan GSTAR (1₁) untuk deret *noise* $\hat{n}_{i,t}$ dengan persamaan :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{20} & 0 \\ 0 & 0 & \phi_{30} \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{21} & 0 \\ 0 & 0 & \phi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12}w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31}w_{32} & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Sehingga estimasi parameter model GSTAR (1₁) di tiga lokasi berbeda dapat dituliskan sebagai berikut :

$$n_{1,t} = \phi_{10}n_{1,t-1} + \phi_{11}w_{12}n_{2,t-1} + \phi_{11}w_{13}n_{3,t-1} + \varepsilon_{1,t},$$

$$n_{2,t} = \phi_{20}n_{2,t-1} + \phi_{21}w_{21}n_{1,t-1} + \phi_{21}w_{23}n_{3,t-1} + \varepsilon_{2,t},$$

$$n_{3,t} = \phi_{30}n_{3,t-1} + \phi_{31}w_{31}n_{1,t-1} + \phi_{31}w_{32}n_{2,t-1} + \varepsilon_{3,t}.$$

Jika $V_{i,t} = \sum_{j \neq i} w_{ij}n_{j,t}$ maka model diatas dapat dibentuk dalam notasi matriks sebagai berikut:

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} n_{1,t-1} & 0 & 0 & V_{1,t-1} & 0 & 0 \\ 0 & n_{2,t-1} & 0 & 0 & V_{2,t-1} & 0 \\ 0 & 0 & n_{3,t-1} & 0 & 0 & V_{3,t-1} \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{20} \\ \phi_{30} \\ \phi_{11} \\ \phi_{21} \\ \phi_{31} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

- b. Estimasi terhadap parameter $\beta = (\phi_{10} \phi_{20} \phi_{30} \phi_{11} \phi_{21} \phi_{31})'$ yaitu dengan persamaan $\hat{\beta} = (\mathbf{X}'\Sigma^{-1} \otimes \mathbf{I}\mathbf{X})^{-1} \mathbf{X}'\Sigma^{-1} \otimes \mathbf{I}\mathbf{Y}$.

2.8 Diagnostic Checking Model

Dalam mengecek apakah suatu model yang diduga telah memenuhi syarat kebaikan model atau belum dapat melakukan diagnostic checking model. Suatu model dikatakan layak jika parameter model tersebut sudah signifikan dan residual dari model telah memenuhi asumsi *white noise*. Residual bersifat *white noise* apabila residual dari masing-masing data saling independen. Uji *White Noise* dilakukan dengan cara memodelkan ulang residual yang diperoleh dari pemodelan. White Noise dapat dideteksi dengan melihat plot MCCF atau menggunakan kriteria nilai minimum dari AIC (Wei, 2006). Jika nilai AIC terkecil terletak pada AR (0) dan MA (0), maka dapat dikatakan bahwa tidak ada korelasi antar residual, artinya residual bersifat *white noise*.

2.9 Kriteria Pemilihan Model Terbaik

Salah satu kriteria kebaikan model yang banyak digunakan yaitu *Root Mean Square Error* (RMSE). Suatu model dugaan dikatakan sebagai model terbaik didapatkan jika nilai RMSE model tersebut paling kecil dibandingkan dengan nilai RMSE model yang lain. Hal ini sesuai dengan tujuan peramalan yaitu memperoleh angka ramalan dengan tingkat kesalahan terkecil. Rumus umum yang digunakan untuk memperoleh nilai RMSE, yaitu (Hassani *et al.*, 2009):

$$RMSE = \sqrt{\frac{\sum_{l=1}^M (Y_{n+l} - \hat{Y}_n(l))^2}{M}}.$$

M menyatakan banyaknya ramalan yang dilakukan, Y_{n+l} adalah data sebenarnya dan $\hat{Y}_n(l)$ adalah hasil ramalan pada l -langkah ke depan.

2.10 Inflasi

Fenomena inflasi merupakan fenomena moneter dimana naik turunnya inflasi cenderung mengakibatkan gejolak ekonomi. Inflasi secara umum merupakan suatu kondisi naiknya harga barang-barang secara umum pada periode waktu tertentu (Sukirno, 2008). Inflasi diukur dari perubahan persentase pada biaya pembelian sekelompok barang dan jasa yang tercakup oleh suatu indeks dikurangi 100 (Lipsey *et al.*, 1992).

Indikator yang sering digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK). Perubahan IHK dari waktu ke waktu menunjukkan pergerakan harga dari paket barang dan jasa yang dikonsumsi masyarakat. Tahun 2007 Badan Pusat Statistik (BPS) melaksanakan Survei Biaya Hidup (SBH), sehingga sejak tahun 2008 paket barang dan jasa dalam keranjang IHK telah berdasar pada SBH. SBH terakhir dilaksanakan pada tahun 2012 dengan penambahan 8 kota inflasi baru dan pembaruan paket komoditas. Perkembangan harga barang-barang dalam kurun waktu tertentu dipantau secara berkala baik pada pasar tradisional maupun pasar modern di berbagai kota target perhitungan inflasi. IHK dikelompokkan ke dalam 7 kelompok pengeluaran (berdasarkan *the Classification of individual consumption by purpose* - COICOP), yaitu :

- a) Kelompok Bahan Makanan.
- b) Kelompok Makanan Jadi, Minuman, dan Tembakau.
- c) Kelompok Perumahan.
- d) Kelompok Sandang.
- e) Kelompok Kesehatan.
- f) Kelompok Pendidikan dan Olah Raga.
- g) Kelompok Transportasi dan Komunikasi.

Setiap kelompok terdiri dari beberapa sub kelompok yang mencakup beberapa komoditas dimana setiap bulan dipantau perubahan harganya. Khusus untuk kelompok bahan makanan terdiri dari 11 sub kelompok yaitu, [1] Padi-padian, umbi-umbian dan hasilnya, [2] Daging dan hasilnya, [3] Ikan segar, [4] Ikan diawetkan, [5] Telur, Susu dan hasil-hasilnya, [6] Sayur-sayuran, [7] Kacang-kacangan, [8] Buah-buahan, [9] Bumbu-bumbuan, [10] Lemak dan Minyak, [11] Bahan Makanan Lainnya. Perubahan harga tersebut akan dihitung melalui rumusan IHK setiap bulannya.

Perhitungan IHK pada masing-masing kota inflasi menggunakan tahun dasar tertentu berdasarkan data harga suatu komoditas yang diperoleh dari hasil observasi setiap bulan dibandingkan dengan data harga komoditas yang sama pada bulan sebelumnya yang hasilnya disebut relatif harga. Selanjutnya relatif harga dikalikan dengan nilai konsumsi bulan sebelumnya, kemudian hasilnya

dibagi dengan nilai konsumsi tahun dasar dan dikali 100 maka akan diperoleh indeks bulan bersangkutan (BPS,2016).

Perhitungan indeks tersebut secara umum dijabarkan sebagai formula Indeks Laspeyres yang dimodifikasi (*Laspeyres Index Modified*), yaitu :

$$IHK_n = \frac{\sum_{i=1}^k \frac{P_{ni}}{P_{(n-1)i}} P_{(n-1)i} Q_{0i}}{\sum_i P_{0i} \cdot Q_{0i}} \times 100,$$

dimana: IHK_n = Indeks Harga Konsumen bulan ke-n,
 P_{ni} = Harga Jenis barang i pada bulan ke (n),
 $P_{(n-1)i}$ = Harga Jenis barang i pada bulan ke (n-1),
 $\frac{P_{ni}}{P_{(n-1)i}}$ = Relatif Harga (RH) jenis barang i pada bulan ke (n),
 $P_{(n-1)i} Q_{0i}$ = Nilai Konsumsi (NK) jenis barang i pada bulan ke (n-1),
 $P_{0i} Q_{0i}$ = Nilai Konsumsi (NK) jenis barang i pada tahun dasar,
 k = Jumlah jenis barang yang tercakup dalam paket komoditas.

Indeks sub kelompok diperoleh dengan cara membagi nilai konsumsi sub kelompok yang bersangkutan pada bulan berjalan dengan nilai konsumsi sub kelompok yang sama pada tahun dasar dikalikan 100. Nilai konsumsi sub kelompok merupakan penjumlahan nilai konsumsi dari seluruh jenis barang dan jasa yang tercakup dalam sub kelompok yang bersangkutan. Adapun indeks kelompok diperoleh dengan cara membagi nilai konsumsi kelompok yang bersangkutan pada bulan berjalan dengan nilai konsumsi kelompok yang sama pada tahun dasar dikalikan 100. Nilai konsumsi kelompok merupakan penjumlahan nilai konsumsi dari seluruh jenis barang dan jasa yang tercakup dalam kelompok yang bersangkutan.

Demikian juga dengan indeks umum diperoleh dengan cara membagi nilai konsumsi umum suatu kota pada bulan berjalan dengan nilai konsumsi umum kota bersangkutan pada tahun dasar dikalikan 100. Nilai konsumsi umum

merupakan penjumlahan nilai konsumsi dari seluruh jenis barang dan jasa yang terpilih pada kota yang bersangkutan.

Untuk memperoleh persentase (%) perubahan indeks atau laju inflasi/deflasi setiap bulan, yaitu dengan mengurangi indeks (IHK sub kelompok/kelompok/umum) suatu bulan dengan indeks (IHK sub kelompok/kelompok/ umum) bulan sebelumnya dan dibagi dengan indeks (IHK sub kelompok/kelompok/umum) bulan sebelumnya dikalikan 100 atau indeks (IHK sub kelompok/kelompok/umum) suatu bulan dibagi dengan indeks (IHK sub kelompok/ kelompok/umum) bulan sebelumnya, hasilnya dikurang dengan 1 dan dikalikan dengan 100, atau dapat ditulis seperti dalam persamaan berikut :

$$L[I, D]_n = \frac{I_n - I_{(n-1)}}{I_{(n-1)}} \times 100,$$

dimana: $L[I, D]_n$ = Laju inflasi/deflasi bulan ke-n,

I_n = Indeks bulan ke-n,

$I_{(n-1)}$ = Indeks bulan ke-(n-1).

Sehubungan dengan tujuan menjaga stabilitas inflasi, Bank Indonesia (BI) diberikan kewenangan moneter oleh pemerintah untuk menjaga kestabilan angka inflasi pada nilai yang wajar. Pentingnya pengendalian inflasi didasarkan pada pertimbangan bahwa inflasi yang stabil dapat memberikan manfaat yang positif diantaranya, secara makro dapat menciptakan kestabilan bagi pelaku ekonomi dan bisnis dalam pengambilan keputusan investasi yang pada akhirnya pemerintah dapat dengan mudah menentukan target pertumbuhan ekonomi (Bank Indonesia, 2013). Selain itu, dengan stabilnya angka inflasi pemerintah dapat menjaga pendapatan riil masyarakat dan secara tidak langsung pemerintah menjaga agar tidak bertambahnya jumlah masyarakat yang berada dibawah garis kemiskinan (Sukirno, 2008).

Meskipun BI memiliki kewenangan untuk mengeluarkan kebijakan yang berdampak pada terjadinya pengendalian angka inflasi, akan tetapi masih ada faktor luar yang turut berpengaruh inflasi. Secara teoritis, timbulnya inflasi sebagai dampak adanya tekanan dari sisi supply (*cost push inflation*) maupun dari sisi permintaan (*demand pull inflation*). Namun dalam perkembangannya, faktor lain yang juga dapat mempengaruhi tingkat inflasi, antara lain naiknya gaji

pegawai negeri, adanya hari besar keagamaan serta kebijakan pemerintah dalam penyesuaian harga Bahan Bakar Minyak (BBM) dan Tarif Dasar Listrik (TDL). Terhambatnya jalur distribusi yang mengakibatkan berkurangnya persediaan barang dipasaran juga menjadi penentu naiknya harga barang. Sehingga, dapat disimpulkan kewenangan BI selaku pemegang otoritas moneter di Indonesia hanya memiliki kemampuan untuk mempengaruhi tekanan inflasi yang berasal dari *demand pull inflation*, sedangkan tekanan inflasi dari *cost push inflation* berada di luar pengendalian Bank Indonesia.

2.11 Faktor Cuaca

Faktor Cuaca (*Weather and Climate Risk*) adalah istilah yang banyak digunakan dalam melihat dampak pengaruh ekstrim cuaca dan iklim terhadap kehidupan manusia. Perubahan cuaca berupa hujan, suhu, kecepatan angin dan kemarau dalam waktu lama tercakup dalam konteks iklim. Perubahan ekstrim dari cuaca tersebut merupakan interaksi kompleks dari atmosfer, matahari, vegetasi, lautan dan aktivitas manusia yang dikenal dengan *climate changes*. Sehingga pada kondisi ini, perlu adaptasi, mitigasi dan penggunaan informasi guna mengurangi kerentanan dan meningkatkan ketahanan masyarakat untuk menahan dampak perubahan ekstrim tersebut.

Indonesia sebagai negara kepulauan dengan luas lautnya 5,8 juta Km², menempatkan kelautan sebagai bagian yang penting dalam pembangunan sosial maupun ekonomi. Jika dikalkulasi secara ekonomi, potensi kelautan Indonesia antara lain dari sektor perikanan sebesar US\$29 miliar per tahun, potensi pariwisata bahari sebesar US\$ 29 miliar per tahun, transportasi laut US\$ 90 miliar per tahun serta masih banyak lagi potensi lainnya (Sudirman Saad dalam Berita Satu, 2013). Mengingat besarnya potensi tersebut, perlu usaha yang besar dalam mengoptimalkan manfaat sumber daya kelautan Indonesia.

Dalam dunia pelayaran, kondisi setiap saat di wilayah perairan dipantau seperti kelembapan, arus laut, arah angin serta kecepatan angin. Informasi cuaca harian tersebut penting guna meminimalisir cuaca buruk saat pelayaran. Hal yang paling berpengaruh adalah kondisi dari kecepatan angin yang berhembus. Kecepatan angin adalah kondisi dari kecepatan angin laut. Kecepatan angin

adalah jarak tempuh angin atau pergerakan udara per satuan 2 waktu dan dinyatakan dalam satuan meter per detik (m/d), kilometer per jam (kpj), dan mil per jam (mpj). Selain kecepatan angin, informasi arah pergerakan angin harian juga diperlukan terutama oleh kapal-kapal nelayan kecil. Kedua unsur cuaca tersebut digunakan untuk mempertahankan posisi saat berlayar.

Khusus untuk wilayah perairan Indonesia bagian timur, arah pergerakan angin banyak dipengaruhi oleh angin musiman, yaitu angin musim barat dan musim timur. Angin musim barat berlangsung mulai sekitar bulan Oktober dan berakhir sekitar bulan Maret; angin musim timur berlangsung sekitar bulan April sampai sekitar bulan September. Pada musim angin tersebut berlangsung, tinggi gelombang yang terjadi lebih tinggi dibandingkan diluar bulan-bulan tersebut.

Faktor iklim lain yang berpengaruh terhadap kehidupan manusia yaitu tinggi gelombang. Faktor ini tidak hanya berpengaruh pada ketersediaan produksi bahan makanan dari sektor perikanan namun juga berpengaruh dalam hal transportasi laut. Dalam dunia pelayaran, informasi tentang gelombang laut sangat diperlukan guna keselamatan pelayaran. Setiap kapal yang berlayar diatur oleh undang-undang untuk wajib memiliki alat bantu navigasi pelayaran dan telekomunikasi pelayaran guna menjamin keselamatan berlayar. Setiap kapal wajib melaporkan jika terdapat indikasi cuaca buruk ke kantor pelayanan maritim Badan Meteorologi, Klimatologi dan Geofisika (BMKG) terdekat agar dapat diteruskan ke kapal lain yang berlayar disekitarnya.

Menurut definisi keilmuan, gelombang laut dapat diartikan sebagai deretan pulsa-pulsa yang berurutan yang terlihat sebagai perubahan ketinggian permukaan air laut yaitu dari elevasi maksimum (puncak) ke elevasi minimum / rendah. Istilah lain dalam pengukuran gelombang laut antara lain, *crest*, *through*, *waveheight*, *wavelength*, *waveperiod* dan *steepness*. Kriteria tinggi gelombang yang mempengaruhi pelayaran dan terkategori sebagai cuaca buruk, yaitu :

1. 0.25 – 2.0 m : berbahaya bagi perahu nelayan.
2. 2.0 – 3.0 m : berbahaya bagi perahu nelayan dan tongkang.
3. 3.0 – 4.0 m : berbahaya bagi perahu nelayan, tongkang dan ferry.
4. > 4.0 m : berbahaya bagi semua kapal.

Dalam hal pembentuk tinggi gelombang laut, terdapat tiga faktor yang mempengaruhi (Hutabarat dan Evans, 1995), yaitu :

- a. Kecepatan angin, jika kecepatan angin tinggi maka gelombang yang terbentuk juga akan semakin besar.
- b. Waktu dimana angin bertiup, kecepatan, dan panjang gelombang cenderung meningkat, sesuai meningkatnya waktu.
- c. Jarak tanpa rintangan, tanpa angin selang bertiup, gelombang yang terbentuk di danau dimana fetch kemungkinan lebih besar, seiring panjang gelombang.

Sedangkan berdasarkan perbandingan antara kedalaman air dan panjang gelombang, maka gelombang dapat diklasifikasikan menjadi tiga macam (Nawisworo dan Sarlina, 2006), yaitu :

1. Gelombang di Laut Dangkal
2. Gelombang di Laut Transisi
3. Gelombang di Laut Dalam.

Data faktor cuaca diperoleh dari ECMWF (*European Centre for Medium-Range Weather Forecasts*) yang dapat diunduh dari <http://ecmwf.int/>. Metode pemrosesan data yang digunakan adalah re-analisis, model dan asimilasi (*numerical weather prediction*) data satelit serta data *insitu*. ECMWF adalah sebuah lembaga organisasi internasional yang didukung oleh 31 negara Eropa dan sekita tujuh organisasi meteorologi dunia, seperti World Meteorological Organisation (WMO).

Metode re-analisis data yang digunakan yaitu ERA-Intern dengan hasil peramalan yang lebih baik dari metode sebelumnya. Data kecepatan angin diperoleh dari hasil pengukuran vektor kecepatan angin dan temperatur pada lapisan atmofisik terendah. Sedangkan kecepatan angin permukaan laut dan tekanan atmofisik menjadi input yang penting dalam menghitung tinggi gelombang. Parameter perhitungan kecepatan angin dihitung pada ketinggian 10 meter pada komponen vektor u dan v dalam satuan meter/detik. Sedangkan tinggi gelombang signifikan dalam satuan meter. Data disajikan dalam bentuk grid dengan full resolusi ($0,75^\circ \times 0,75^\circ$) atau dalam skala asli $80 \text{ Km} \times 80 \text{ Km}$. Data terakhir menyebutkan penurunan RMSE pada data tinggi gelombang berkisar 0,4 - 1,25 m.

Dalam laporan singkat tahun 2012, ECMWF mengklain bahwa perbedaan hasil perhtungan data kecepatan angin dan pengukuran yang dilakukan olehEuropean Space Agency (ESA) berkisar 0,25 m. Pengukuran satelit ESA memberikan hasil *real time* dan informasi yang berskala global.

Data bulanan merupakan integrasi dari beberapa data kelautan-atmofsir dan merupakan rata-rata data mingguan yang sudah dilakukan peramalan 10 hari ke depan menggunakan Wave Model (WAM). Data tersebut sudah memperhitungkan adanya anomali cuaca, sehingga rata-rata Root Mean Square Error (RMSE) dari data peramalan yang digunakan sekitar 0,3 – 0,7 meter dari data yang bersumber dari *buoy*. *Buoy* merupakan salah satu altimeter gelombang (Jessen *et al.*, 1997).

BAB 3

METODOLOGI PENELITIAN

Pada bab ini akan dijelaskan tentang metodologi yang digunakan dalam rangka mencapai tujuan penelitian, meliputi sumber data, variabel penelitian, definisi operasional dan tahapan analisis.

3.1 Sumber Data

Data yang digunakan pada penelitian ini, yaitu data sekunder yang bersumber dari website bps.go.id berupa data inflasi bahan makanan serta data tinggi gelombang dan kecepatan angin yang diperoleh dari <http://apps.ecmwf.int/datasets/data/interim-full-daily>. Data inflasi bahan makanan yang dimaksud adalah data inflasi bahan makanan di Kota Sorong, Manokwari dan Jayapura dari bulan Januari 2008 sampai dengan Desember 2015. Demikian pula dengan batasan waktu data tinggi gelombang dan kecepatan angin yang dipergunakan di masing-masing kota yaitu mulai Januari 2008 hingga Desember 2015. Data periode Januari 2008 sampai dengan Desember 2014 digunakan sebagai data training (*in-sample*) sedangkan data Januari 2015 sampai dengan Desember 2015 sebagai data testing (*out-sample*). Data jarak tempuh kapal serta jumlah moda transportasi antar wilayah di Papua yang digunakan pada penelitian dapat dilihat pada Tabel 3.1 dan Tabel 3.2 berikut.

Tabel 3.1 Jumlah Moda Transportasi Laut yang Melayani antar Lokasi Kota Inflasi di Papua

Asal	Tujuan		
	Jayapura	Manokwari	Sorong
Jayapura	0	6	8
Manokwari	6	0	8
Sorong	8	8	0

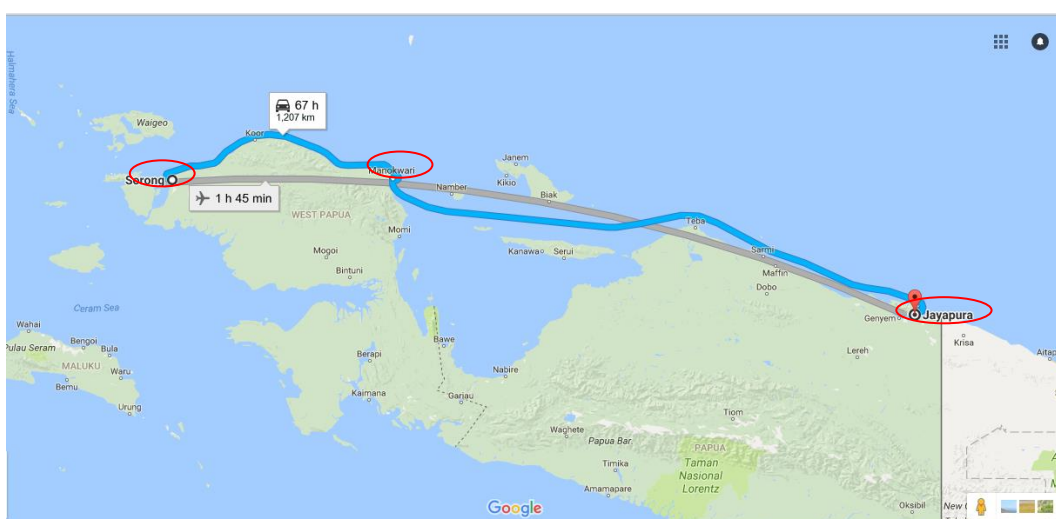
Sumber: www.pelni.go.id.

Tabel 3.2 Jarak Tempuh Kapal dengan Transportasi Laut antar Lokasi di Papua

Asal	Tujuan/Jarak (Km)		
	Jayapura	Manokwari	Sorong
Jayapura	0	824	1207
Manokwari	824	0	390
Sorong	1207	390	0

Sumber: www.maps.google.com (diolah)

Lokasi dari ketiga kota di Pulau Papua dapat dilihat pada peta di bawah ini:



Gambar 3.1 Peta lokasi kota inflasi di Pulau Papua (www.maps.google.com)

3.2 Variabel Penelitian

3.2.1. Variabel Output

Jika $Y_{i,t}$ merupakan data *output* pada lokasi ke- i dengan $i = 1,2,3$ (Kota Sorong, Manokwari, Jayapura) dan waktu ke- t maka variabel *output* yang digunakan dalam penelitian ini seperti ditunjukkan pada Tabel 3.1.

Tabel 3.3 Variabel *Output* dalam Penelitian

No	Variabel	Keterangan
1.	$Y_{1,t}$	Inflasi Bahan Makanan Kota Sorong waktu ke- t
2.	$Y_{2,t}$	Inflasi Bahan Makanan Kab Manokwari waktu ke- t
3.	$Y_{3,t}$	Inflasi Bahan Makanan Kota Jayapura waktu ke- t

3.2.2. Variabel Input

Definisi variable *input* dalam penelitian ini yaitu rata-rata tinggi gelombang dan rata-rata kecepatan angin di kota inflasi ke i waktu ke t . Sehingga dapat didefinisikan dengan simbol variabel $x_{hi,t}$, yaitu :

Tabel 3.4 Variabel *Input* dalam Penelitian

No	Variabel	Keterangan
1.	$X_{11,t}$	Rata-rata Tinggi gelombang Kota Sorong waktu ke- t
2.	$X_{12,t}$	Rata-rata Tinggi gelombang Kab Manokwari waktu ke- t
3.	$X_{13,t}$	Rata-rata Tinggi gelombang Kota Jayapura waktu ke- t
4.	$X_{21,t}$	Rata-rata Kecepatan Angin Kota Sorong waktu ke- t
5.	$X_{22,t}$	Rata-rata Kecepatan Angin Kab Manokwari waktu ke- t
6.	$X_{23,t}$	Rata-rata Kecepatan Angin Kota Jayapura waktu ke- t

3.3 Tahapan Analisis Data

Berdasarkan tujuan penelitian maka tahapan dalam penelitian ini adalah melakukan pemodelan data inflasi kelompok bahan makanan pada tiga kota di Papua, yaitu Sorong, Manokwari, Jayapura. Namun, sebelumnya diperlukan analisis deskriptif dan membuat plot *time series* untuk masing-masing lokasi/kota.

3.4 Pemodelan ARIMA

Proses peramalan inflasi kelompok bahan makanan dengan pemodelan ARIMA dilakukan sesuai dengan prosedur Box-Jenkins. yaitu:

1. Mengidentifikasi stasioneritas dalam varians dan rata-rata pada data inflasi di masing-masing lokasi.
2. Melakukan identifikasi model dugaan sementara pada data di masing-masing lokasi.
3. Melakukan estimasi parameter model di masing-masing lokasi.

4. Melakukan pemeriksaan diagnosa untuk mendapatkan model yang sesuai dengan memeriksa residual untuk mengetahui tercapainya syarat asumsi residual yang *white noise* dan berdistribusi normal.
5. Melakukan peramalan berdasarkan model yang layak dan menghitung RMSE pada data *out-sample*.

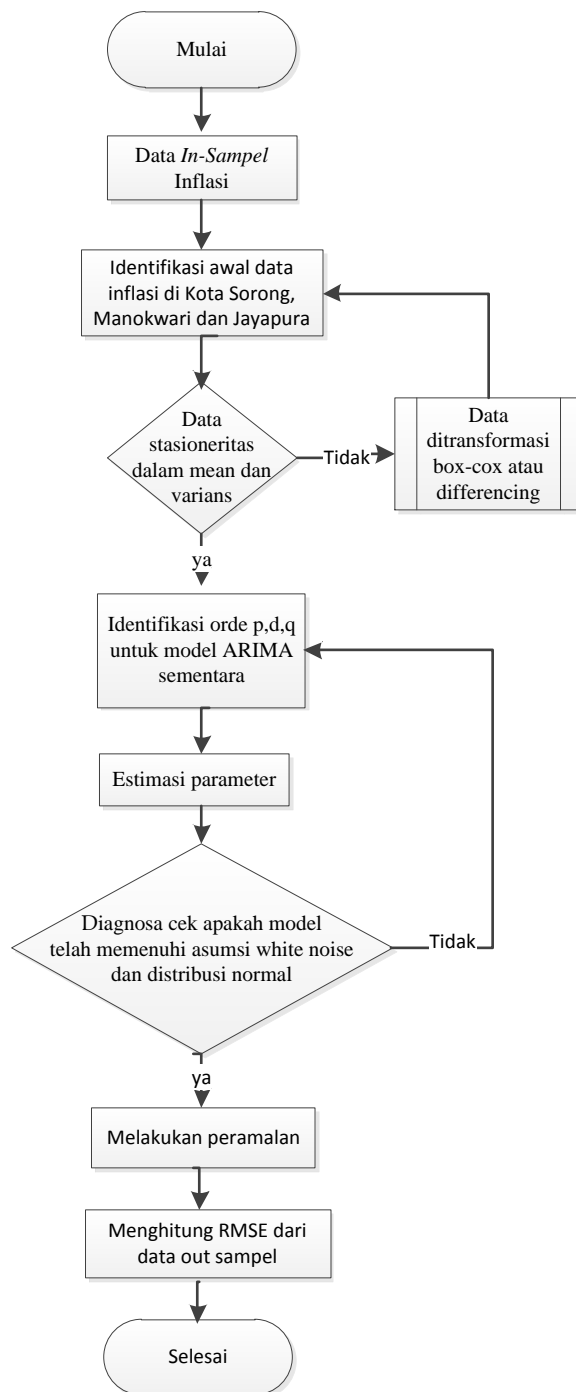
3.5 Pemodelan Fungsi Transfer

Misalkan lokasi setiap kota di Papua di indekskan dengan $i = 1,2,3$ dan jumlah variabel input di indekskan dengan $j = 1,2$. Maka, tahapan pemodelan fungsi transfer yang akan dilakukan meliputi:

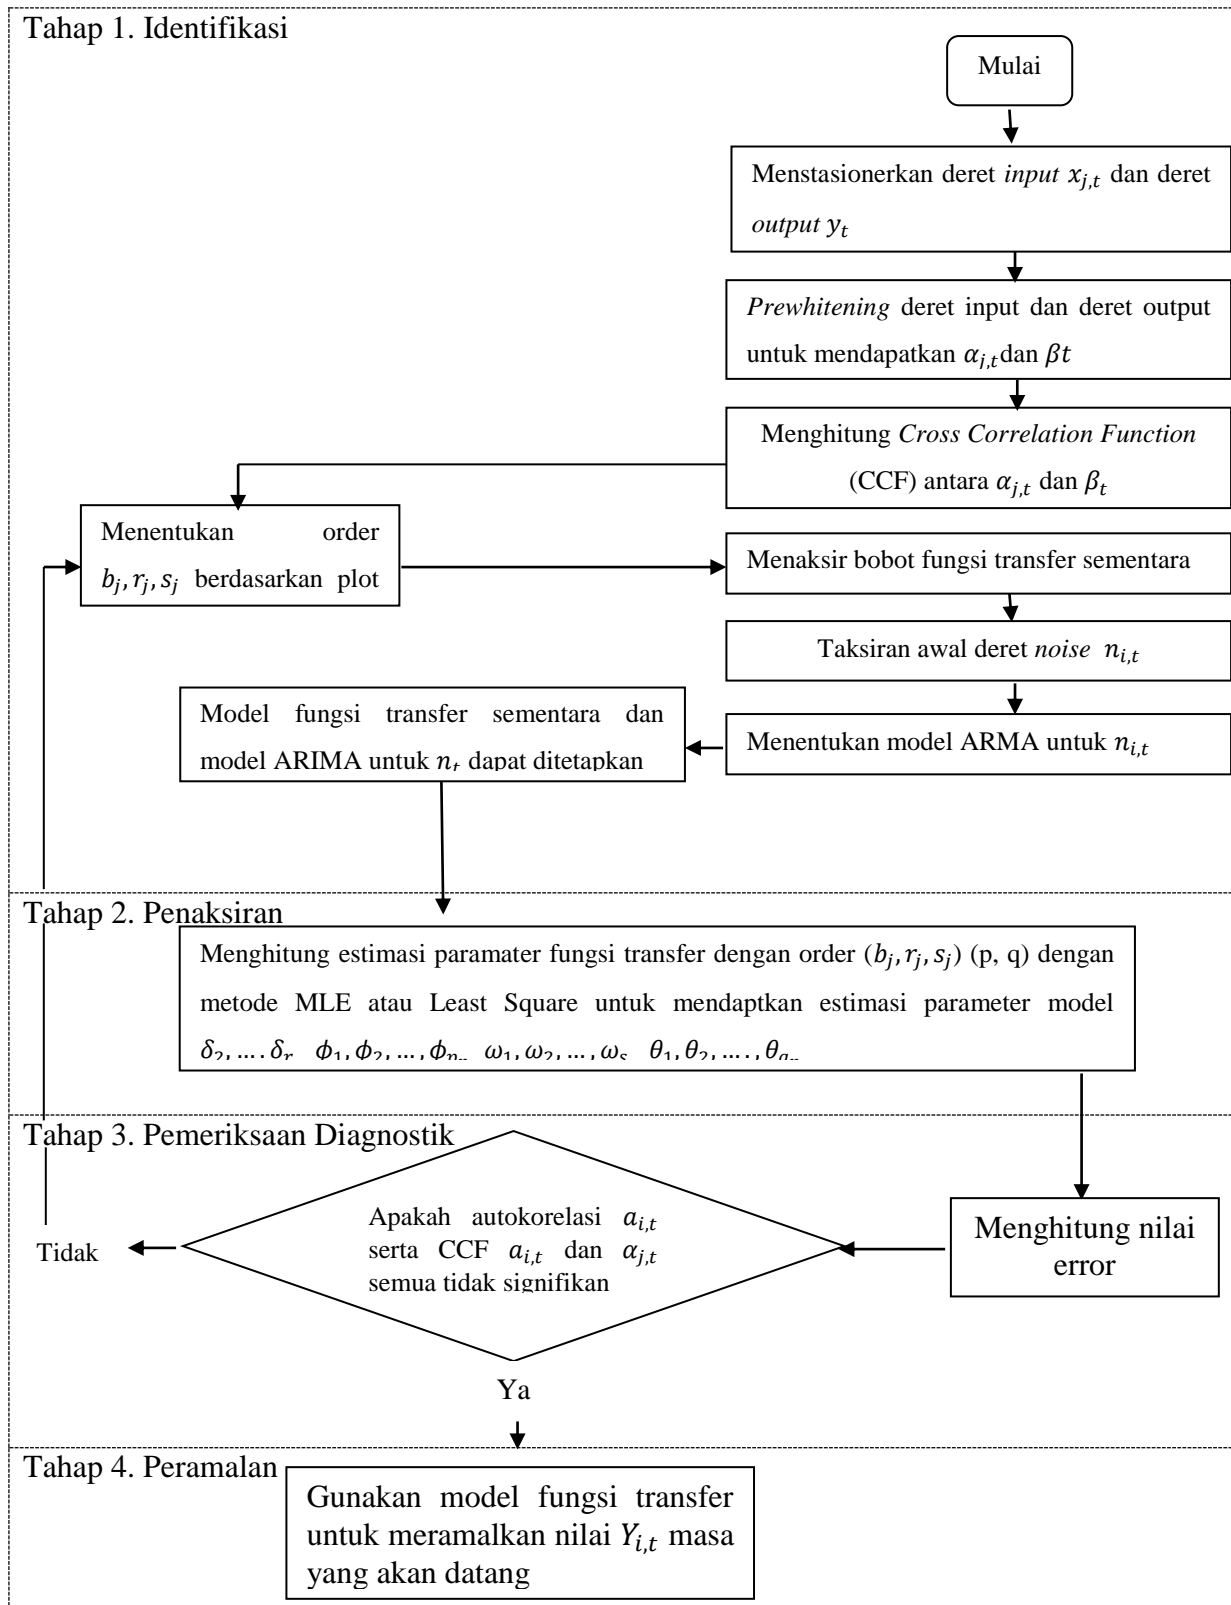
1. Mempersiapkan deret *input* dan deret *output*, dengan deret *input* yang telah stasioner.
2. Melakukan *prewhitening* pada data deret *input* dan deret *output*.
3. Menghitung CCF antara koefisien deret *input* dan *output* yang telah melalui proses *prewhitening*.
4. Menetapkan orde (b_j, s_j, r_j) yang menghubungkan masing-masing data deret *input* dan deret *output* serta penaksiran awal parameter model dan menghitung deret *noise* $n_{i,t}$.
5. Melakukan pemodelan dengan model fungsi transfer sementara berdasarkan orde (b_j, s_j, r_j) dan pemodelan ARMA untuk $n_{i,t}$.
6. Melakukan estimasi parameter model fungsi transfer multi input, sehingga diperoleh model sebagai berikut:

$$y_t = \sum_{j=1}^2 \frac{\omega_{s_j}(B)B^{b_j}}{\delta_{r_j}(B)} x_{j,t} + \frac{\theta_q(B)}{\phi_p(B)} a_{i,t} \quad 3.1$$

7. *Diagnostic checking* model untuk mendapatkan model yang layak dengan memeriksa residual untuk mengetahui tercapainya asumsi residual yang *white noise* dan berdistribusi normal.
8. Melakukan peramalan dengan model terbaik dan menghitung nilai RMSE pada data *out-sample*.



Gambar 3.2 Tahapan Pemodelan Inflasi dengan Model ARIMA



Gambar 3.3 Tahapan Pemodelan Inflasi dengan Model Fungsi Transfer

3.6 Pembentukan Model GSTARX

Tahapan pembentukan model GSTARX dari residual fungsi transfer (a_{it}) dengan $i = 1, 2, 3$ pada penelitian ini meliputi:

1. Pada tahap pertama melakukan estimasi parameter fungsi transfer pada masing-masing kota seperti yang telah dijelaskan sebelumnya. Sehingga mendapatkan model transfer tanpa melakukan pemodelan ARMA deret *noise* $n_{i,t}$
2. Pada tahap kedua melakukan langkah-langkah sebagai berikut:
 - a. Mengidentifikasi stasioneritas dalam rata-rata dari residual $n_{i,t}$ dengan menggunakan skematik MCCF.
 - b. Menentukan orde AR (p) dari data n_{it} yang telah stasioner dengan menggunakan skematik MPCCF.
 - c. Menentukan bobot spasial yang digunakan, bobot lokasi yang dipergunakan ditentukan dengan orde spasial satu (p_1).
 - d. Melakukan penghitungan nilai pembobot lokasi (W^1) menggunakan bobot lokasi yang biasa digunakan dalam analisis GSTAR, bobot konektivitas dan bobot matriks segi tiga atas. Penggunaan matriks bobot didasari oleh dua hipotesis, yaitu :
 - Hipotesis 1 : berfungsi sebagai eksploratori, menggunakan matriks bobot yang umum digunakan pada model GSTAR.
 - Hipotesis 2 : berfungsi sebagai konfirmatori, menggunakan matriks bobot segi tiga atas (*Upper Triangular Matrix*) sebagai restriksi atas jalur distribusi pangan dari luar Pulau Papua, , sehingga matriks yang digunakan yaitu :

$$W = \begin{bmatrix} 0 & w_{12} & w_{13} \\ 0 & 0 & w_{23} \\ 0 & 0 & 0 \end{bmatrix}$$

Dengan $\sum_{j=1}^3 w_{1j} = 1, \sum_j w_{2j} \neq 1, \sum_{j=1}^3 w_{3j} = 0$

w_{1j} = bobot pada Kota Jayapura

w_{2j} = bobot pada Kota Manokwari

w_{3j} = bobot pada Kota Sorong

- e. Melakukan estimasi parameter model AR orde p dari langkah 2 bagian (b) dari model GSTAR-GLS

$$n, t = \sum_{k=1}^p [\Phi_{k0} u_{t-k} + \Phi_{k1} W^{(1)} u_{t-k}] + \varepsilon_t \quad 3.2$$

- f. Menguji signifikansi parameter model GSTAR-GLS. Jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan mengurangi variabel yang tidak signifikan.
- g. Mendapatkan model GSTAR-GLS.
- h. Melakukan peramalan $\hat{n}_{i,t}$ dengan model GSTAR-GLS.
3. Pada tahap ketiga langkah-langkah yang dilakukan dalam pemodelan GSTARX adalah sebagai berikut:
- a. Melakukan peramalan dengan model GSTARX untuk data inflasi bahan makanan di Papua dengan formula:

$$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{n}_{i,t} \quad 3.3$$

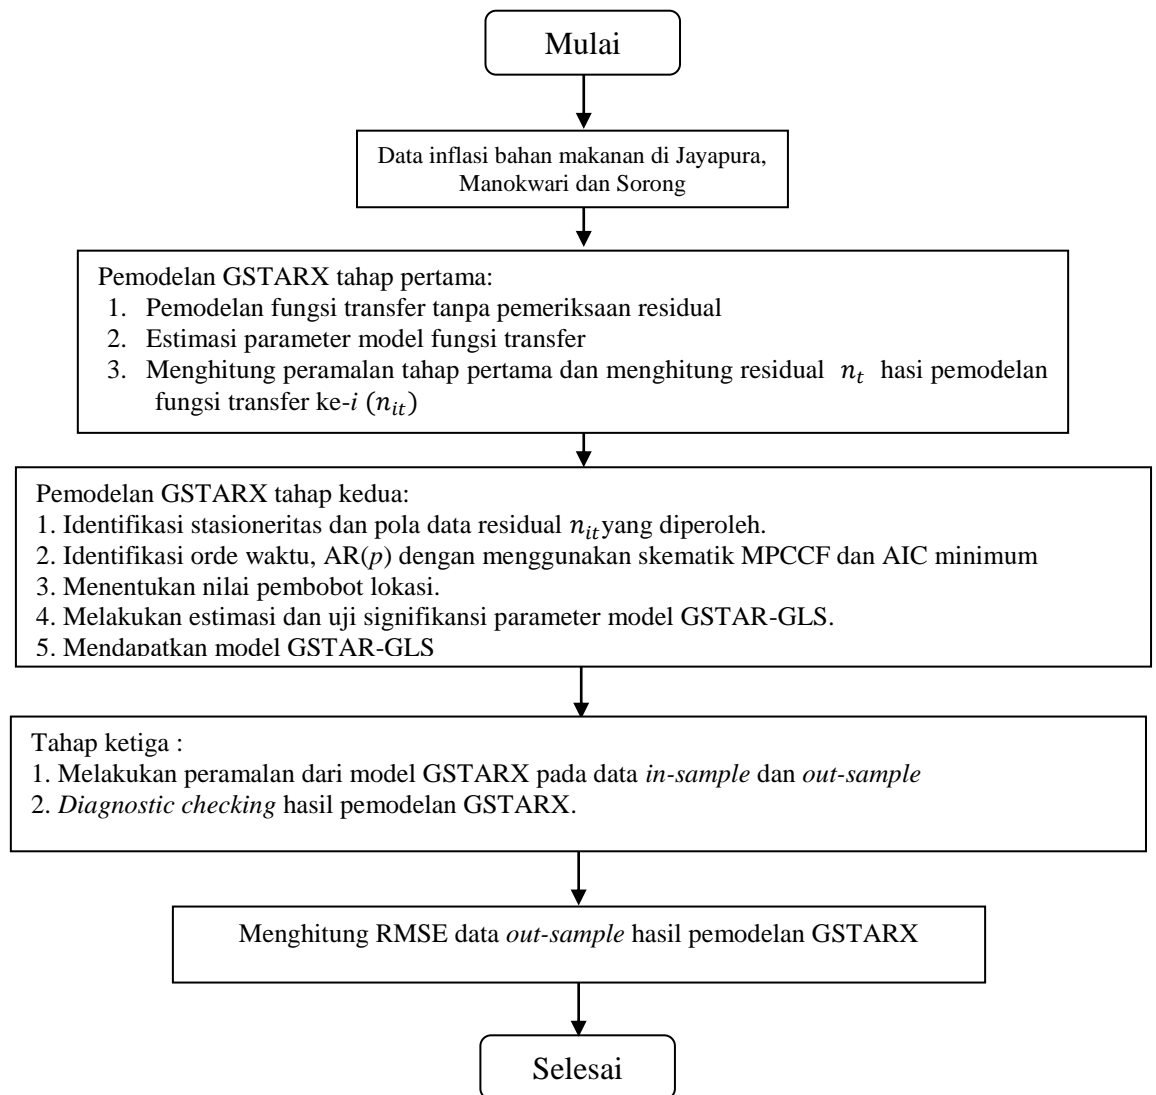
dengan

$\hat{Y}_{i,t}$: hasil ramalan ke- t di lokasi ke- i dari model GSTARX

$\hat{y}_{i,t}$: hasil ramalan ke- t di lokasi ke- i di tahap I

$\hat{n}_{i,t}$: hasil ramalan ke- t di lokasi ke- i di tahap II

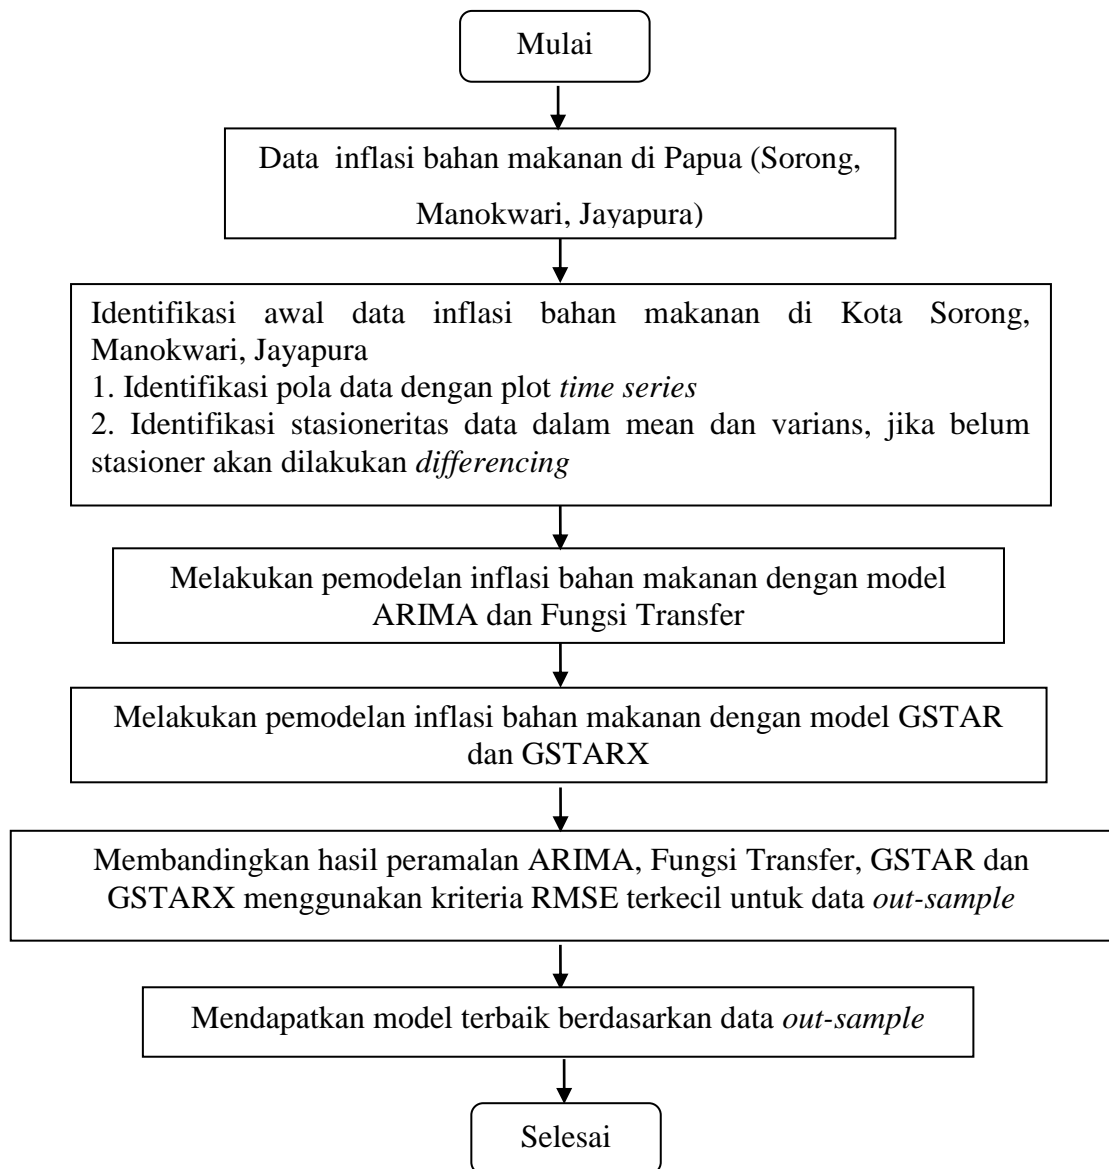
- b. *Diagnostic checking* hasil pemodelan GSTARX dengan pengujian residual yang *white noise* menggunakan AIC yang terkecil.
- c. Menghitung nilai RMSE hasil pemodelan GSTARX pada data *out-sample*.



Gambar 3.4 Tahapan Pemodelan Inflasi dengan model GSTARX

3.7 Pemilihan Model Terbaik

1. Membandingkan hasil peramalan GSTARX model ARIMA, dan model fungsi transfer menggunakan kriteria model RMSE untuk data *out-sample*.
2. Mendapatkan model terbaik berdasarkan data *out-sample*.



Gambar 3.5 Tahapan Pemilihan Model Terbaik

3.8 Struktur Data dalam Penelitian Data Inflasi Bahan Makanan Kota Inflasi di Pulau Papua

Struktur data yang dipergunakan dalam penelitian ini seperti yang terlihat pada Tabel 3.5 berikut:

Tabel 3.5 Struktur Data dalam Penelitian Inflasi Bahan Makanan di Pulau Papua

Tahun	Bulan	t	$Y_{1,t}$	$Y_{2,t}$	$Y_{3,t}$	$X_{11,t}$	$X_{12,t}$	$X_{13,t}$	$X_{21,t}$	$X_{22,t}$	$X_{23,t}$
2008	1	1	$y_{1,1}$	$y_{2,1}$	$y_{3,1}$	$x_{11,1}$	$x_{12,1}$	$x_{13,1}$	$x_{21,1}$	$x_{22,1}$	$x_{23,1}$
2008	2	2	$y_{1,2}$	$y_{2,2}$	$y_{3,2}$	$x_{11,2}$	$x_{12,2}$	$x_{13,2}$	$x_{21,2}$	$x_{22,2}$	$x_{23,2}$
2008	3	3	$y_{1,3}$	$y_{2,3}$	$y_{3,3}$	$x_{11,3}$	$x_{12,3}$	$x_{13,3}$	$x_{21,3}$	$x_{22,3}$	$x_{23,3}$
2008	4	4	$y_{1,4}$	$y_{2,4}$	$y_{3,4}$	$x_{11,4}$	$x_{12,4}$	$x_{13,4}$	$x_{21,4}$	$x_{22,4}$	$x_{23,4}$
2008	5	5	$y_{1,5}$	$y_{2,5}$	$y_{3,5}$	$x_{11,5}$	$x_{12,5}$	$x_{13,5}$	$x_{21,5}$	$x_{22,5}$	$x_{23,5}$
2008	6	6	$y_{1,6}$	$y_{2,6}$	$y_{3,6}$	$x_{11,6}$	$x_{12,6}$	$x_{13,6}$	$x_{21,6}$	$x_{22,6}$	$x_{23,6}$
2008	7	7	$y_{1,7}$	$y_{2,7}$	$y_{3,7}$	$x_{11,7}$	$x_{12,7}$	$x_{13,7}$	$x_{21,7}$	$x_{22,7}$	$x_{23,7}$
2008	8	8	$y_{1,8}$	$y_{2,8}$	$y_{3,8}$	$x_{11,8}$	$x_{12,8}$	$x_{13,8}$	$x_{21,8}$	$x_{22,8}$	$x_{23,8}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	7	91	$y_{1,91}$	$y_{2,91}$	$y_{3,91}$	$x_{11,91}$	$x_{12,91}$	$x_{13,91}$	$x_{21,91}$	$x_{22,91}$	$x_{23,91}$
2015	8	92	$y_{1,92}$	$y_{2,92}$	$y_{3,92}$	$x_{11,92}$	$x_{12,92}$	$x_{13,92}$	$x_{21,92}$	$x_{22,92}$	$x_{23,92}$
2015	9	93	$y_{1,93}$	$y_{2,93}$	$y_{3,93}$	$x_{11,93}$	$x_{12,93}$	$x_{13,93}$	$x_{21,93}$	$x_{22,93}$	$x_{23,93}$
2015	10	94	$y_{1,94}$	$y_{2,94}$	$y_{3,94}$	$x_{11,94}$	$x_{12,94}$	$x_{13,94}$	$x_{21,94}$	$x_{22,94}$	$x_{23,94}$
2015	11	95	$y_{1,95}$	$y_{2,95}$	$y_{3,95}$	$x_{11,95}$	$x_{12,95}$	$x_{13,95}$	$x_{21,95}$	$x_{22,95}$	$x_{23,95}$
2015	12	96	$y_{1,96}$	$y_{2,96}$	$y_{3,96}$	$x_{11,96}$	$x_{12,96}$	$x_{13,96}$	$x_{21,96}$	$x_{22,96}$	$x_{23,96}$

BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini membahas mengenai ramalan inflasi kota di Pulau Papua, Kota Sorong, Manokwari dan Jayapura dengan metode ARIMA, Fungsi Transfer GSTAR dan GSTAR-X dengan input data metrik. Analisis yang dilakukan meliputi pencarian model terbaik sehingga dapat digunakan untuk meramalkan inflasi bahan makanan di Pulau Papua pada beberapa waktu kedepan.

4.1 Gambaran Umum Inflasi Bahan Makanan di Pulau Papua

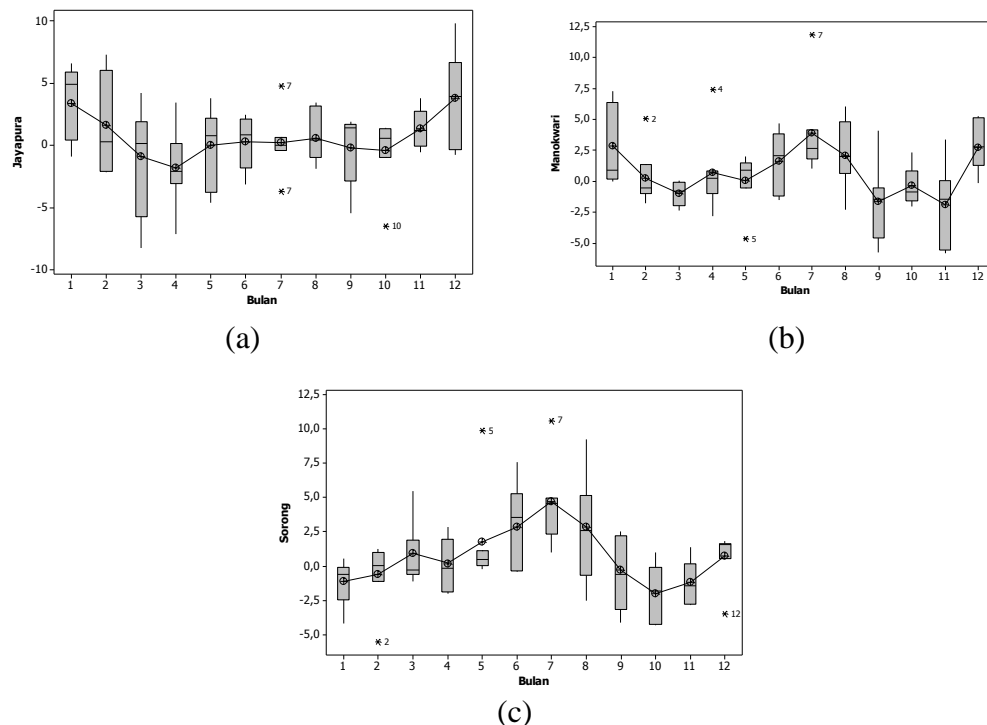
Karakteristik dan informasi data inflasi bahan makanan pada masing-masing kota inflasi di Pulau Papua dapat terangkum dengan jelas melalui analisis deksriptif. Data yang digunakan pada penelitian ini adalah data series inflasi bahan makanan di Kota Sorong, Manokwari dan Jayapura sejak bulan Januari 2008 hingga bulan Desember 2014 sebagai data *in-sample* dan data bulan Januari 2015 hingga Desember 2015 sebagai data *out-sample*.

Tabel 4.1 Statistik Deskriptif Data Inflasi di Tiga Lokasi

Lokasi	<i>Mean</i>	Standar Deviasi	Minimum	Maksimum
Kota Jayapura	0,663	3,261	-8,23	9,80
Kota Manokwari	0,747	3,062	-5,82	11,79
Kota Sorong	0,719	3,081	-5,53	10,6

Berdasarkan Tabel 4.1 diketahui rata-rata inflasi bahan makanan di Kota Manokwari sebesar 0,747 persen dengan tingkat keragaman sebesar 3,062 persen. Demikian pula dengan rata-rata inflasi bahan makanan di Kota Sorong tercatat 0,719 dengan tingkat variasi sebesar 3,081. Hal yang sedikit berbeda dengan rata-rata inflasi bahan makanan di Kota Jayapura, tercatat lebih rendah dibandingkan dengan dua kota lainnya sebesar 0,663. Namun, tingkat variasi yang lebih tinggi sebesar 3,261. Hal ini mengindikasikan fluktuasi kebutuhan konsumsi bahan makanan masyarakat di Kota Jayapura relatif lebih tinggi dibandingkan dua kota lainnya. Kota Jayapura merupakan kota administratif yang pembentukannya lebih

dahulu dibandingkan kedua kota lainnya, sehingga keberagaman masyarakat dan aktivitas ekonomi turut mempengaruhi dinamika konsumsi masyarakatnya.

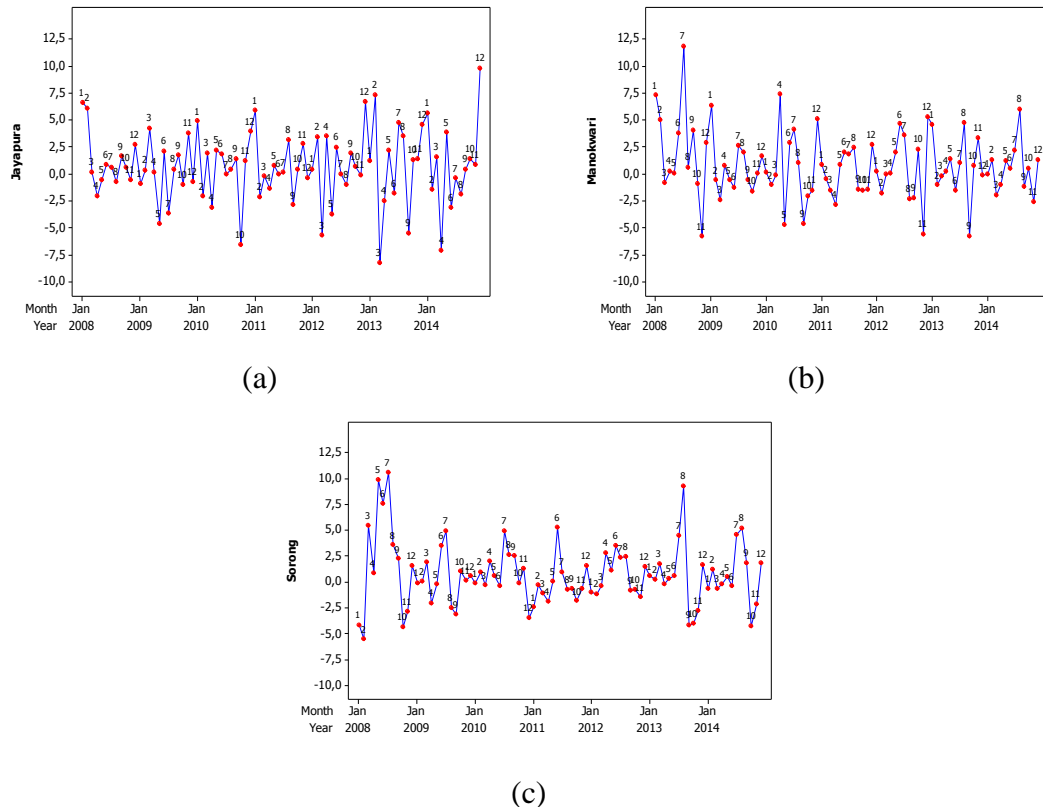


Gambar 4.1 Box-Plot Inflasi Bahan Makanan (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong

Gambar 4.1 menunjukkan kecenderungan pola persebaran data inflasi bahan makanan berdasarkan bulan di masing-masing lokasi. Persebaran data inflasi per bulan di masing-masing lokasi cenderung memiliki sebaran data yang heteroden dengan adanya *outlier* sehingga boxplot yang terbentuk tidak simetris. Inflasi terendah pernah terjadi di Kota Jayapura pada bulan maret 2013 sebesar -8,23 persen dan inflasi tertinggi terjadi di Kota Manokwari pada bulan juli 2008 sebesar 11,79 persen. Pola persebaran yang lebih heterogen terhadap inflasi bahan makanan setiap bulannya terjadi di Kota Jayapura, terlihat dari IQR (*Interquartile Range*) boxplot di Kota Jayapura yang lebih di tinggi dibandingkan dengan lokasi lain di bulan yang sama. Hal ini mengindikasikan, perubahan harga komoditas bahan pangan di Kota Jayapura lebih fluktuatif, sangat rentan terjadi kenaikan ataupun penurunan harga yang relatif ekstrim.

Inflasi bahan makan terendah di Kota Manokwari terjadi pada bulan november 2008 sebesar -5,82 persen dan tertinggi terjadi pada bulan juli 2008

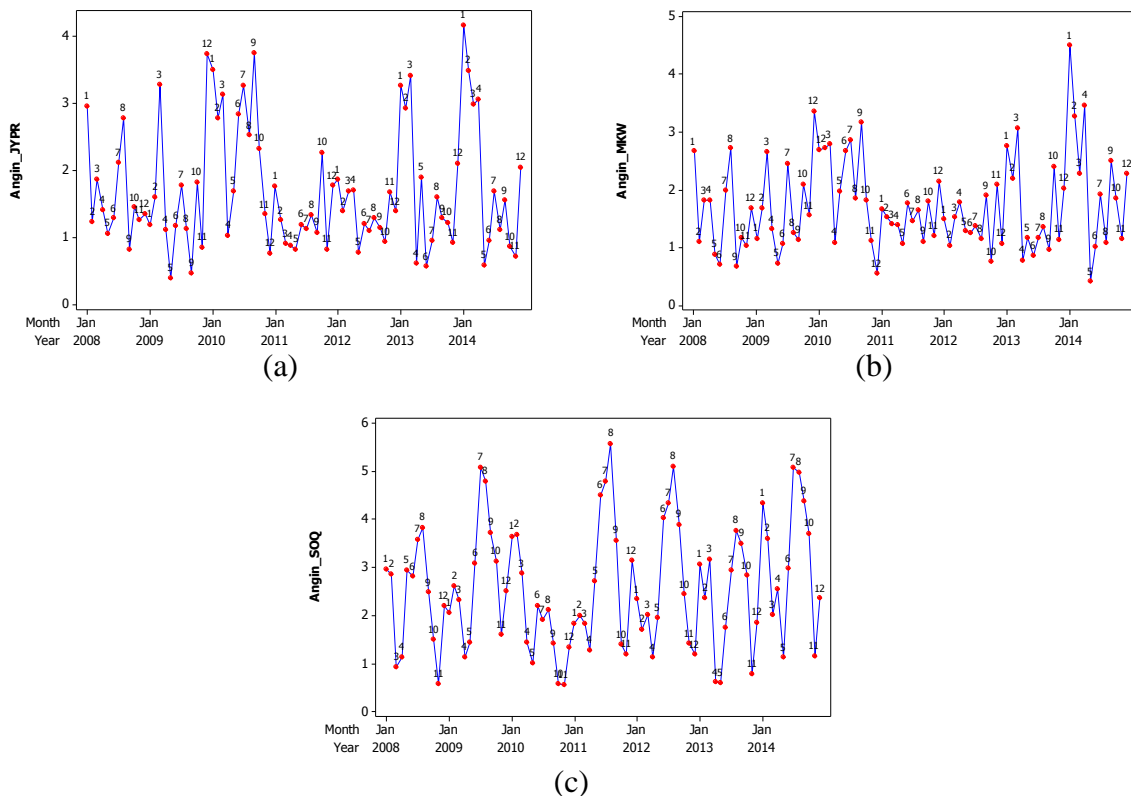
sebesar 11,79 persen. Adapun inflasi bahan makanan terendah terjadi di Kota Sorong pada bulan februari tahun 2008 sebesar -5,53 persen dan tertinggi pada bulan juli 2008 sebesar 10,6 persen. Sedangkan inflasi bahan makanan terendah yang terjadi di Kota Jayapura terjadi pada bulan maret 2013 sebesar -8,23 persen dan tertinggi pada bulan desember 2014 sebesar 9,8 persen.



Gambar 4.2 Plot Time Series Inflasi Bahan Makanan (a) Kota Jayapura (b) Kota Manokwari(c) Kota Sorong

Penurunan tekanan inflasi yang signifikan pada kelompok bahan makanan lebih disebabkan oleh adanya koreksi harga komoditas kelompok pengeluaran bahan makanan bulan tersebut dibandingkan harga bulan sebelumnya. Demikian pula ketika terjadi kenaikan inflasi yang sangat signifikan, kenaikan harga komoditas lebih disebabkan oleh tidak seimbangnya sisi permintaan dan penawaran komoditas pangan dipasaran. Sisi penawaran komoditas kelompok bahan makanan di Pulau Papua masih ditopang oleh produksi dari luar Pulau Papua, hal dikarenakan produksi lokal tidak mampu bersaing dalam pemenuhan konsumsi masyarakat perkotaan.

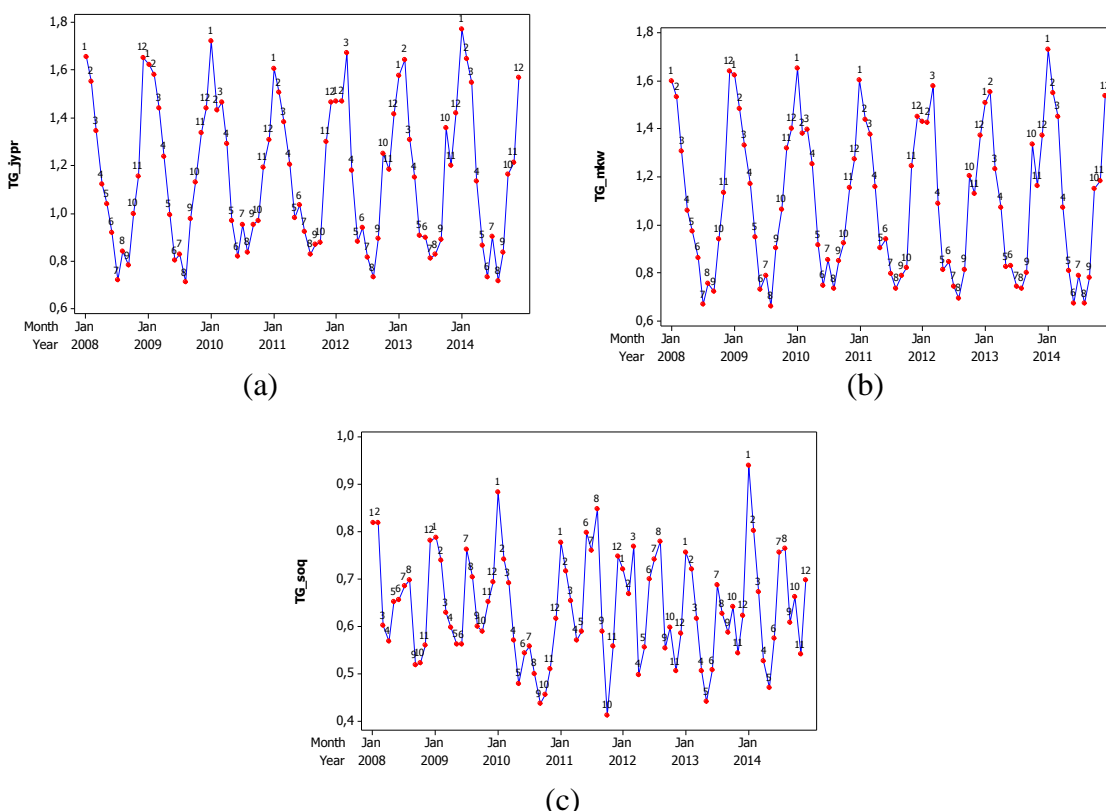
Nilai inflasi di tiga lokasi Pulau Papua disajikan pada Gambar 4.2 menunjukkan plot time series dari data inflasi bahan makanan pada tiga lokasi kota inflasi di Pulau Papua, Kota Manokwari, Kota Sorong dan Kota Jayapura. Masing-masing plot menunjukkan pergerakan inflasi di masing-masing kota dengan pola yang cenderung sama. Kenaikan harga bahan pokok menjelang hari raya natal menjadi penyebab pada bulan Desember (bulan ke 12) terjadi kenaikan inflasi yang lebih tinggi dibandingkan bulan lainnya ditahun yang sama. Selain itu, pola kenaikan inflasi yang signifikan juga terjadi di Kota Manokwari dan Sorong pada bulan Juli (bulan ke 7) setiap tahunnya. Pola kenaikan inflasi setiap bulan juli cenderung dipengaruhi oleh kenaikan harga salah satu sub kelompok bahan makanan, yaitu sub kelompok ikan segar. Cuaca buruk berupa angin kencang dan tinggi gelombang yang relatif tinggi menyebabkan berkurangnya sisi penawaran komoditas tersebut di pasaran.



Gambar 4.3 Plot Time Series Kecepatan Angin di Tiga Lokasi di Pulau Papua (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong

Kondisi cuaca khususnya kecepatan angin dari periode bulan Januari 2008 hingga bulan Desember 2014 di Kota Manowari, Kota Sorong dan Kota

Jayapura disajikan pada Gambar 4.3. Pada bulan di triwulan II maupun triwulan IV ditahun yang sama bahkan saat memasuki awal triwulan I ditahun berikutnya, masih terlihat bahwa kecepatan angin lebih tinggi dibandingkan bulan lainnya. Hal ini mendukung fakta bahwa pada waktu tersebut terjadi kenaikan inflasi pada kelompok bahan makanan.



Gambar 4.4 Plot Time Series Tinggi Gelombang di Tiga Lokasi di Pulau Papua (a) Kota Jayapura (b) Kota Manokwari (c) Kota Sorong

Data tinggi gelombang juga mendukung fakta tersebut. Pada bulan Desember tercatat ketinggian gelombang pada perairan di sekitar Kota Manokwari, Kota Sorong dan Kota Jayapura relatif lebih tinggi, hingga mencapai 1,7 meter (*moderate sea*). Kondisi cuaca tersebut belum masuk dalam kategori buruk namun cukup membahayakan nelayan pesisir dan memicu kenaikan inflasi pada sub kelompok ikan segar. Pola time series yang siklis menunjukkan bahwa data tinggi gelombang memiliki pola musiman. Pola data tersebut dipengaruhi oleh angin musiman (muson timur dan muson barat) yang arah pergerakannya berubah setiap enam bulan sekali.

Tabel 4.2 menunjukkan statistik deskriptif dari variabel faktor cuaca. Rata-rata tinggi gelombang yang bergerak disekitar 0,638 - 1,163 meter pada wilayah Kota Sorong, Manokwari dan Jayapura masih dalam kategori *moderate sea*. Pada kategori tersebut standar deviasi data menunjukan nilai 0,112 - 0,303 meter. Hal ini berarti fluktuasi data tidak terjadi serta tidak termasuk dalam kategori cuaca yang ekstrim. Rata-rata kecepatan angin yang berkisar antara 1,699 – 2,557 meter/detik dengan standar deviasi 0,910-1,274 meter/detik cenderung berfluktuatif. Kecepatan angin dengan nilai maksimum 4,163 - 5,573 meter/detik cukup mempengaruhi penangkapan ikan oleh nelayan pesisir.

Tabel 4.2 Statistik Deskriptif Data Cuaca di Tiga Lokasi di Pulau Papua

Stat.	Tinggi Gelombang (m)			Kecepatan Angin (m/s)		
	Jayapura	Manokwari	Sorong	Jayapura	Manokwari	Sorong
Deskriptif						
Mean	1,1638	1,1042	0,6385	1,6996	1,7179	2,557
Std.Deviasi	0,3036	0,3124	0,1128	0,9104	0,7861	1,274
Min	0,7113	0,6618	0,4112	0,3993	0,4143	0,548
Maks	1,7709	1,7303	0,9387	4,1636	4,4962	5,573


4.2 Pemodelan ARIMA pada Inflasi Bahan Makanan Tiga Kota di Pulau Papua

Pemodelan ARIMA menggunakan prosedur pemodelan Box-Jenkins yang dibagi dalam beberapa tahap, yaitu identifikasi stasioneritas, estimasi, *diagnostic check* (verifikasi) dan peramalan. Berikut pemodelan ARIMA inflasi bahan makanan pada tiga kota di Pulau Papua.

4.2.1. Peramalan ARIMA pada Inflasi Bahan Makanan Kota Jayapura

Tahapan identifikasi stasioneritas pada model ARIMA dapat dilakukan dengan melihat plot Box-Cox *Transformation* dan plot ACF. Stasioneritas terbagi menjadi dua, stasioneritas dalam varian dan stasioneritas dalam rata-rata. Pengujian stasioneritas data tahap awal dapat dengan memeriksa, apakah data telah stasioner dalam varians. Karena data inflasi bahan makanan masih mengandung nilai negatif, maka untuk mempositifkan nilai tersebut dapat dengan


menambahkan suatu konstanta berupa nilai minimum pada deret time series ditambah satu. Deret data baru tersebut dapat diuji box-cox tranformation, jika nilai lambda (λ) sama dengan satu, dapat dikatakan data telah stasioner dalam varians.



Gambar 4.5 Box-Cox *Transformation* setelah di tambahkan Konstanta (JYPR)

Gambar 4.5 menunjukkan nilai λ satu, sehingga dapat disimpulkan bahwa deret data baru tersebut tidak perlu dilakukan transformasi lebih lanjut atau data telah stasioner dalam varians. Dengan demikian, deret data time series yang selanjutnya digunakan adalah data awal (*origin*).

Gambar 4.6 menunjukkan data telah stasioner dalam mean dengan tidak adanya lag yang turun melambat baik pada lag non musiman maupun musiman. Penentuan orde dari model ARIMA sementara dapat dengan mengidentifikasi lag signifikan pada plot ACF maupun PACf dari deret data yang telah stasioner.



Gambar 4.6 Plot (a) ACF dan (b) PACF Inflasi Bahan Makanan di Kota Jayapura

Berdasarkan lag-lag yang signifikan pada plot ACF dan PACF Gambar 4.6, plot ACF *cut off* pada lag 5 sedangkan PACF *cut off* pada lag 5 dan 9. Model

sementara ARIMA inflasi bahan makanan di Jayapura yaitu $([9],0,0)$. Prosedur Box-Jenkins selanjutnya yaitu mengestimasi parameter berdasarkan lag-lag yang signifikan. Hasil pengujian signifikansi dari estimasi parameter pada model tersebut, tersaji pada Tabel 4.3.

Tabel 4.3 Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Jayapura

Model ARIMA	Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
$([9],0,0)$	μ	0,654	0,270	2,420	0,018
	ϕ_9	-0,305	0,119	-2,570	0,012

Estimasi parameter model dugaan ARIMA pada Tabel 4.3 signifikan pada taraf $\alpha = 5\%$ dengan *p-value* dibawah 0,05. Prosedur selanjutnya yaitu *diagnostic check* untuk melihat kesesuaian model apakah residual memenuhi asumsi *white noise* dan berdistribusi normal. Pada taraf signifikansi $\alpha = 5\%$, hasil uji Ljung-Box di Tabel 4.4 menunjukkan nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag pada residual model dugaan ARIMA sehingga asumsi residua *white noise* terpenuhi. Output uji McLeod-Li pada Lampiran 10 kolom 3 menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model ARIMA yang terbentuk memiliki varians yang konstan.

Tabel 4.4 Hasil Uji Residual *White Noise* Model ARIMA pada Data Inflasi Bahan Makanan Kota Jayapura

Model ARIMA	Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
$([9],0,0)$	6	6,90	5	0,23
	12	9,50	11	0,58
	18	15,09	17	0,59
	24	21,40	23	0,56


Pengujian asumsi normalitas residual dapat menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorov-Smirnov tidak signifikan pada $\alpha = 5\%$ dengan *p-value* yang lebih besar dari 0,05. Output tersebut memberikan kesimpulan bahwa

residual seluruh model dugaan telah memenuhi asumsi normal. Secara matematis model ARIMA ([9],0,0) dapat ditulis sebagai berikut:

$$y_{1,t} = 0,654 + \frac{1}{(1 + 0,305B^9)} a_{1,t}$$

Prosedur Box-Jenkins selanjutnya yaitu melakukan peramalan 12 langkah ke depan menggunakan model ARIMA ([9],0,0) sehingga plot time series antara data aktual dan peramalan dapat dibandingkan. Gambar 4.7 menunjukkan hanya pada bulan Februari, Maret, Oktober dan November pola ramalan mengikuti pola data aktualnya. Hal ini disebabkan pada bulan-bulan tersebut fluktuasi IBM tidak begitu tinggi. berbeda dengan bulan lainnya, seperti bulan Januari dan Desember tingginya inflasi disebabkan oleh kenaikan permintaan komoditas pangan menjelang hari raya natal dan tahun baru.

Namun, nilai ramalan *out-sample* jika dibandingkan dengan standar deviasi sudah sangat baik hal ini ditunjukkan dengan penurunan nilai yang cukup besar pada RMSE *out-sample*. Pada Gambar 4.7 menunjukkan bahwa RMSE *out-sample* sampai $k = 12$ masih baik dalam melakukan peramalan. RMSE *out-sample* yang tinggi pada $k=1$ menunjukkan pola data Januari tahun 2015 berbeda dengan tahun-tahun sebelumnya yang cenderung rendah.




Gambar 4.7 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk k -step (kanan) ARIMA Jayapura

4.2.2. Peramalan ARIMA pada Inflasi Bahan Makanan Kota Manokwari


Tahapan pemodelan ARIMA pada data inflasi bahan makanan di Kota Manokwari sama dengan pemodelan inflasi di Kota Jayapura. Sebelum menguji

apakah deret data tersebut stasioner, penambahan suatu konstanta perlu dilakukan sehingga deret data bernilai positif.



Gambar 4.8 Plot Box-Cox *Transformation* setelah di tambahkan Konstanta (MKW)

Hasil plot Box-Cox *Transformation* (Gambar 4.8) menunjukkan data telah stasioner dalam varians dengan nilai $\lambda = 1.0$. Dengan demikian, deret data time series yang digunakan selanjutnya adalah data sebelum ditambahkan suatu konstanta. Plot ACF dan PACF pada pengujian stasioneritas menunjukkan baik pada lag musiman maupun non musiman telah stasioner. Plot ACF maupun PACF telah *cut off* hanya pada lag-lag tertentu. Proses identifikasi selanjutnya yaitu mengidentifikasi orde model ARIMA sementara yang terbentuk berdasarkan plot ACF dan PACF dari deret data yang telah stasioner. Gambar 4.9 menunjukkan baik pada Plot ACF maupun PACF *cut off* pada lag 2 dan 6.



Gambar 4.9 Plot ACF (a) dan PACF (b) Inflasi Bahan Makanan di Kota Manokwari

Dengan demikian, dapat diduga model ARIMA data inflasi bahan makanan kota Manokwari yaitu $([2,6],0,0)$ dan $([6],0,0)$. Prosedur Box-Jenkins selanjutnya

yaitu mengestimasi masing-masing parameter dari model dugaan. Output lengkap hasil estimasi parameter model dugaan ARIMA dapat dilihat pada Tabel 4.5.

Tabel 4.5 Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Manokwari

Model ARIMA	Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
([2,6],0,0)	μ	0,788	0,297	2,660	0,010
	ϕ_2	0,292	0,104	2,800	0,006
	ϕ_6	-0,246	0,107	-2,300	0,024
([6],0,0)	μ	0,843	0,453	1,860	0,067
	ϕ_6	0,324	0,108	3,000	0,004

p-value masing-masing estimasi parameter model dugaan ARIMA memberikan kesimpulan bahwa pada tingkat signifikansi $\alpha = 5\%$, keseluruhan model sementara ARIMA tersebut signifikan dalam menduga nilai inflasi bahan makanan di Manokwari dengan *p-value* kurang dari 0,05. Sehingga prosedur Box-Jenkins selanjutnya yaitu menguji asumsi residual *white noise* dengan uji Ljung-Box.

Tabel 4.6 Hasil Uji Residual *White Noise* Model ARIMA pada Data Inflasi Bahan Makanan Kota Jayapura

Model ARIMA	Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
([2,6],0,0)	6	1,85	4	0,764
	12	10,96	10	0,361
	18	13,6	16	0,629
	24	20,92	22	0,526
([6],0,0)	6	4,97	5	0,420
	12	13,61	11	0,256
	18	14,85	17	0,607
	24	21,74	23	0,536

Tabel 4.6 menunjukan *p-value* uji Ljung-Box lebih dari 0,05 pada tingkat signifikansi $\alpha = 5\%$. Pengujian ini menunjukkan bahwa asumsi residual yang independen terpenuhi. Demikian halnya dengan hasil uji McLeod-Li pada

Lampiran 10 kolom 5 yang menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model ARIMA selain memenuhi asumsi residual yang independen juga identik, atau residual dengan varians yang konstan

Pengujian asumsi apakah residual model normal dapat menggunakan uji Kolmogorof-Smirnov. *p-value* output uji Kolmogorof-Smirnov pada residual untuk seluruh model sementara ARIMA lebih besar dari 0,05 pada taraf signifikansi $\alpha = 5\%$. Meskipun estimasi parameter dari seluruh model dugaan ARIMA tersebut signifikan serta residual model memenuhi asumsi *white noise* dan normal, namun pemilihan model terbaik tetap perlu dilakukan. Beberapa kriteria dapat dilakukan, namun pada penelitian ini kriteria pemilihan model terbaik dapat menggunakan nilai AIC dari masing-masing model dugaan ARIMA. Model terbaik yang terpilih dapat digunakan untuk meramal data k langkah kedepan.

Tabel 4.7 Nilai AIC Model Dugaan ARIMA inflasi Bahan Makanan di Jayapura


Model ARIMA	AIC
([2,6],0,0)	419,25
([6],0,0)	420,68

Berdasarkan kriteria nilai AIC terkecil maka model ARIMA ([2,6],0,0) merupakan model terbaik yang dapat digunakan untuk meramal data k langkah kedepan. Secara matematis model ARIMA ([2,6],0,0) dapat ditulis sebagai berikut:

$$y_{2,t} = 0,788 + \frac{1}{(1 - 0,292B^2 + 0,245B^6)} a_{2,t}$$

Berdasarkan model tersebut, peramalan data inflasi dua belas langkah kedepan dapat dilakukan. Perbandingan data aktual inflasi bahan makanan dan data ramalan *out-sample* dari model ARIMA ([2,6],0,0) dapat dilihat pada Gambar 4.10. Data aktual Kota Manokwari tahun 2015 sangat fluktuatif sehingga tidak cukup tepat dimodelkan menggunakan ARIMA. Terlihat pola yang sama pada bulan Desember, inflasi mencapai titik tertinggi dibanding bulan lainnya. Perbandingan k ramalan kedepan dengan nilai standar deviasi baik hingga $k=7$.

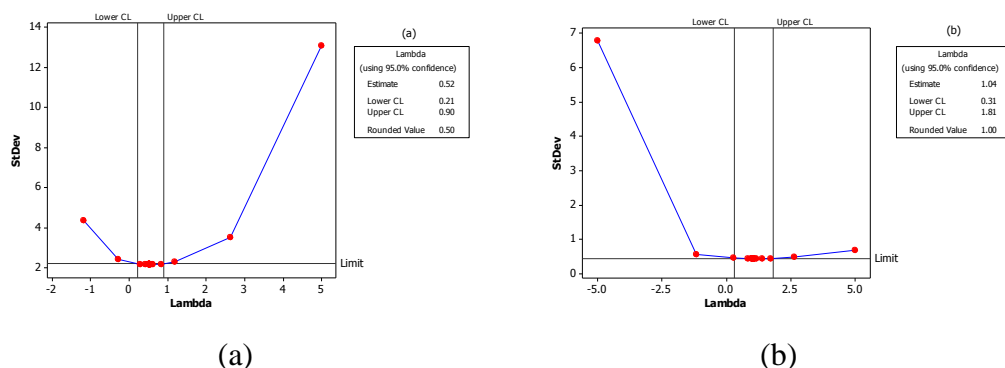
Nilai RMSE hingga ramalan ke 8 sudah tidak dapat mengikuti pola data aktual inflasi di Manokwari. Dibandingkan dua kota lainnya, pola *out-sample* data aktual di Manokwari lebih fluktuatif. Volume tangkapan nelayan yang melebihi permintaan pada bulan Agustus menyebabkan harga ikan segar turun sangat drastis dibanding bulan sebelumnya.



Gambar 4.10 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk *k-step* (kanan) ARIMA Manokwari

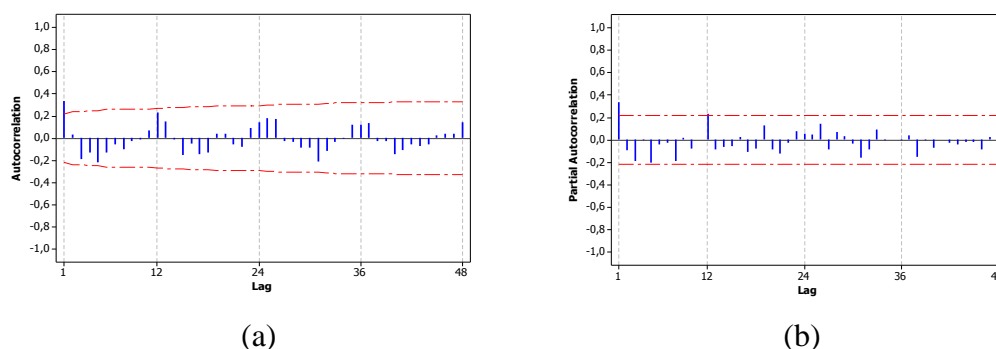
4.2.3. Peramalan ARIMA pada Inflasi Bahan Makanan Kota Sorong

Prosedur Box-Jenkins pada peramalan data inflasi bahan makanan di Kota Sorong dapat dilakukan setelah mempositifkan deret data tersebut. Identifikasi stasioneritas dalam varians melalui plot Box-Cox *Transformation* masih menunjukkan data belum stasioner dalam varians. Sehingga, berdasarkan nilai $\lambda = 0,5$ bentuk transformasi yang digunakan yaitu akar dari nilai inflasi yang telah positif. Gambar 4.12 menunjukkan data telah stasioner dalam varians dengan nilai $\lambda = 1.0$.



Gambar 4.11 Plot Box-Cox data sebelum ditransformasi (a) dan setelah di transformasi akar (b) Inflasi Bahan Makanan di Sorong

Bentuk plot ACF dan PACF dimana hanya pada lag tertentu yang signifikan menunjukan data telah stasioner dalam rata-rata. Proses identifikasi selanjutnya yaitu mengidentifikasi orde model ARIMA yang terbentuk berdasarkan plot ACF dan PACF dari deret data yang telah stasioner. Berdasarkan Gambar 4.12, plot ACF dan PACF masing-masing *cut off* pada lag 1 dan 5.



Gambar 4.12 Plot (a) ACF dan (b) PACF Inflasi Bahan Makanan di Kota Sorong

Model dugaan ARIMA inflasi bahan makanan kota Sorong yaitu (1,0,0) dan (0,0,1). Prosedur Box-Jenkins selanjutnya yaitu mengestimasi masing-masing parameter dari model dugaan. Output lengkap hasil estimasi parameter model dugaan ARIMA dapat dilihat pada Tabel 4.8. Berdasarkan output estimasi parameter pada Tabel 4.8 seluruh parameter telah signifikan pada taraf $\alpha=0,05$. Prosedur selanjutnya yaitu menguji apakah residual dari kedua model tersebut telah memenuhi asumsi *white noise* dan normal dengan *p-value* yang lebih besar dari 0,05 pada taraf signifikansi $\alpha=5\%$. Tabel 4.9 menunjukkan dari dua model yang dipertimbangkan, keduanya memberikan hasil bahwa residual model telah memenuhi asumsi *white noise*. Pengujian asumsi residual normal dapat menggunakan uji Kolmogorov-Smirnov.

Tabel 4.8 Hasil Estimasi Parameter Model ARIMA Data Inflasi Bahan Makanan Kota Sorong

Model ARIMA	Parameter	Estimasi	Standar error	t-value	p-value
(1,0,0)	μ	2,513	0,092	27,390	<0,0001
	ϕ_1	0,315	0,105	3,000	0,004
(0,0,1)	μ	2,519	0,083	30,340	<0,0001
	θ_1	-0,324	0,105	-3,090	0,003

Tabel 4.9 Hasil Uji Residual *White Noise* Model ARIMA pada Data Inflasi Bahan Makanan Kota Sorong

Model ARIMA	Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
(1,0,0)	6	7,94	5	0,160
	12	11,56	11	0,397
	18	17,91	17	0,394
	24	23,38	23	0,439
(0,0,1)	6	8,68	5	0,122
	12	12,37	11	0,337
	18	18,44	17	0,362
	24	22,86	23	0,469

Hasil uji Kolmogorof-Smirnov pada residual kedua model memberikan output dengan *p-value* yang masih kurang dari 0,05. Maka, dapat disimpulkan kedua model tersebut belum memenuhi asumsi residual normal. Pada tahap ini, pemilihan model terbaik sudah dapat dilakukan dengan memilih nilai AIC terkecil sebelum pengolahan lanjut menggunakan ARIMA-outlier.

Tabel 4.10 Nilai AIC Model Dugaan ARIMA inflasi Bahan Makanan di Sorong

Model ARIMA	AIC
(1,0,0)	148,78
(0,0,1)	147,96

Berdasarkan kriteria nilai AIC terkecil maka model ARIMA (0,0,1) merupakan model terbaik yang dapat digunakan untuk meramal data k langkah ke depan. Namun, pemeriksaan data *outlier* perlu dilakukan untuk menyelesaikan permasalahan tidak terpenuhinya asumsi residual berdistribusi normal. Hasil deteksi *outlier* pada pemodelan ARIMA (0,0,1) inflasi bahan makanan di Sorong dapat dilihat pada Tabel 4.11. Hasil deteksi Outlier pada Tabel 4.11 menunjukkan adanya data outlier pada observasi ke 2, 68, 5, 7 dan 82 dengan tipe AO. Nilai *Chi-square* tertinggi terletak pada pengamatan ke-2. Oleh karena itu, estimasi parameter model ARIMA (0,0,1) dilanjutkan dengan menambahkan deteksi outlier pada pengamatan ke-2 dan 68. Apabila asumsi kenormalan belum terpenuhi maka

dapat dilakukan dengan menambahkan deteksi outlier ke pengamatan selanjutnya hingga asumsi residual berdistribusi terpenuhi.

Tabel 4.11 Hasil Deteksi Outlier Model ARIMA (0,0,1) pada Inflasi Bahan Makanan Kota Sorong

Observasi	Tipe	Estimasi Efek Outlier	<i>Chi-Square</i>	<i>p-value</i>
2	<i>Additive</i>	-1,80	17,12	<0,0001
68	<i>Additive</i>	1,44	11,32	0,0008
5	<i>Additive</i>	1,29	9,15	0,0025
7	<i>Additive</i>	1,09	7,15	0,0075
82	<i>Additive</i>	-1,03	6,49	0,0109

Hasil estimasi parameter dengan menambahkan deteksi *outlier* pada pengamatan ke-2 dan 68 dapat dilihat pada Tabel 4.12. Hasil estimasi parameter pada model ARIMA (0,0,1) dengan deteksi *outlier* menunjukkan bahwa pada taraf signifikansi $\alpha=5\%$ seluruh parameter signifikan dengan *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model.

Tabel 4.12 Hasil Estimasi Parameter Model ARIMA (0,0,1) dengan deteksi *outlier* pada Data Inflasi Bahan Makanan Kota Sorong

Parameter	Tipe <i>Outlier</i>	Estimasi	Standar <i>error</i>	<i>t-value</i>	<i>p-value</i>
μ	-	2,519	0,079	31,980	<0,0001
θ_1	-	-0,399	0,108	-3,710	0,000
ω_{LA2}	<i>Additive</i>	-1,776	0,491	-3,620	0,001
ω_{LA68}	<i>Additive</i>	1,443	0,481	3,000	0,004

Selanjutnya, pengujian asumsi residual *white noise* dan berdistribusi normal kembali dilakukan pada model. Hasil uji *white noise* residual pada ARIMA (0,0,1) dengan deteksi *outlier* dapat dilihat pada Tabel 4.13. Hasil uji *white noise* pada Tabel 4.13 menunjukkan bahwa autokorelasi antar esidual model ARIMA (0,0,1) memiliki *p-value* yang lebih besar dari 0,05 yang berarti bahwa autokorelasi tidak signifikan pada taraf $\alpha = 5\%$ atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

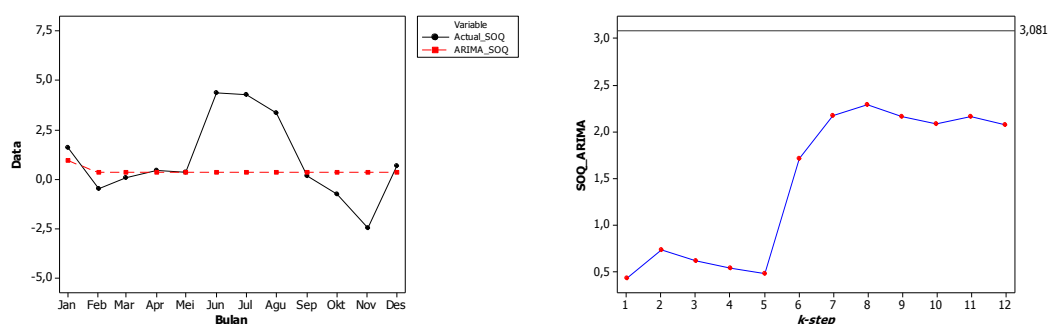
Tabel 4.13 Hasil Uji Residual *White Noise* Model ARIMA dengan Deteksi *Outlier* pada Data Inflasi Bahan Makanan Kota Sorong

Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
6	4,52	5	0,477
12	11,8	11	0,379
18	19,12	17	0,322
24	24,61	23	0,371

.Pengujian asumsi residual identik dapat menggunakan uji McLeod-Li. Output uji McLeod-Li pada Lampiran 10 kolom 7 menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model ARIMA yang terbentuk memiliki varians yang konstan. Hasil uji normalitas Kolmogorov-Smirnov pada residual model ARIMA (0,0,1) dengan deteksi *outlier* sebesar 0,0931 dan *p-value* 0,0722, lebih besar dari 0,05 pada taraf signifikansi $\alpha=5\%$. Dengan demikian, dapat disimpulkan bahwa model ARIMA (0,0,1) dengan deteksi *outlier* telah memenuhi asumsi residual *white noise* yang independen dan identik serta berdistribusi normal sehingga layak dianggap sebagai model terbaik yang dapat digunakan dalam peramalan.

Secara matematis model ARIMA (0,0,1) dengan deteksi *outlier* dapat ditulis sebagai berikut :

$$y_{3,t} = 2,518 - 1,776I_t^{T=2} + 1,443I_t^{T=68} + (1 + 0,399B)a_{3,t}.$$



Gambar 4.13 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk *k-step* (kanan) ARIMA Sorong

Berdasarkan model tersebut, peramalan data inflasi dua belas langkah kedepan dapat dilakukan. Perbandingan data aktual inflasi bahan makanan dan data ramalan *out-sample* dari model ARIMA (0,0,1) dengan deteksi *outier* dapat

dilihat pada Gambar 4.13. Ramalan inflasi model ARIMA dengan deteksi outlier memberikan hasil yang *flat*, bergerak di sekitar rata-rata. Inflasi tertinggi pada data *out-sample* terjadi pada bulan Juli akibatnya peramalan data tidak dapat menangkap fenomena tersebut. Namun, secara umum perbandingan RMSE *out-sample* hingga 12 peramalan kedepan tetap memberikan hasil yang baik karena RMSE out-sample berada di bawah standar deviasi.

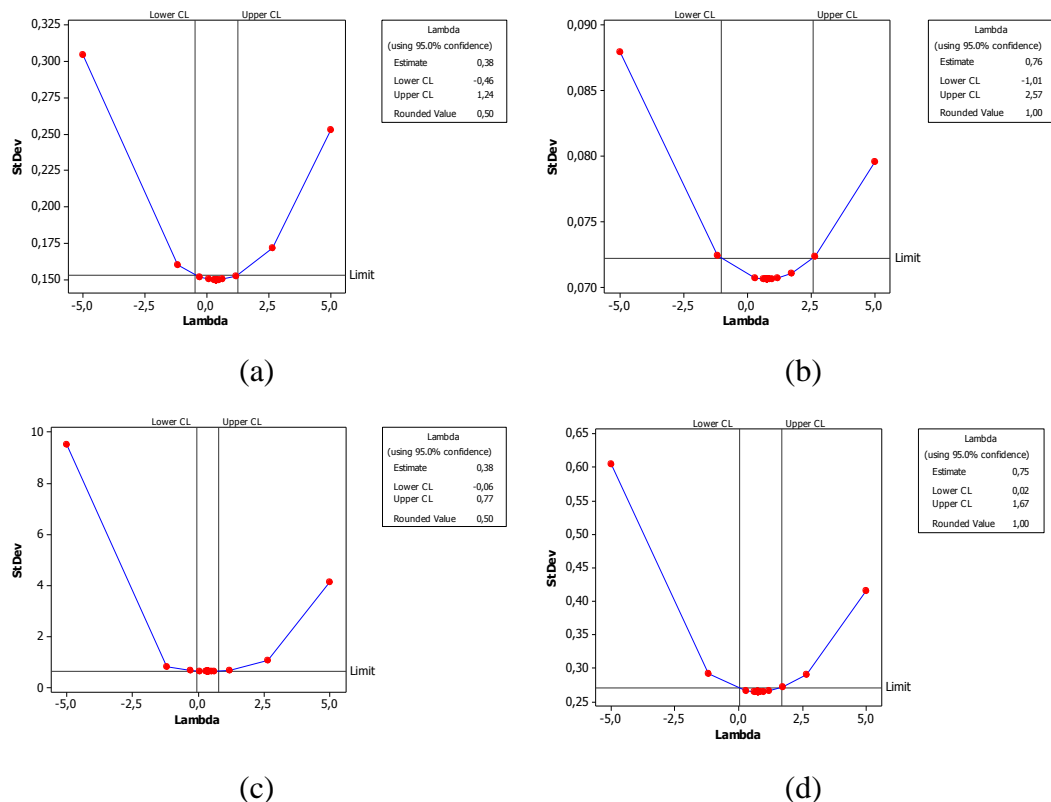
4.3 Pemodelan Fungsi Transfer Inflasi Bahan Makanan di Pulau Papua

Pada tahap ini akan dilakukan pemodelan data inflasi bahan makanan di masing-masing kota dengan menggunakan metode fungsi transfer multi input. Pemodelan fungsi transfer multi input menggunakan dua variabel, yaitu tinggi gelombang (x_{1i}) dan kecepatan angin (x_{2i}).

4.3.1. Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Jayapura


Times series plot untuk dua variabel input di Kota Jayapura menunjukkan pola musiman. Gambar 4.3 dan Gambar 4.4 menunjukkan bahwa pada bulan-bulan tertentu, pola tinggi gelombang sekitar bulan Januari dan Desember relatif lebih tinggi serta bulan Mei hingga Juli cenderung lebih rendah. Sedikit berbeda dengan kondisi kecepatan angin yang cukup berfluktuasi, namun memberikan gambaran bahwa pada penghujung tahun sekitar Desember dan awal Januari, pola kecepatan angin lebih tinggi dibandingkan dengan bulan-bulan yang lainnya. Kondisi cuaca tersebut menyebabkan relatif tingginya inflasi beberapa sub kelompok inflasi bahan makanan, yaitu inflasi kelompok ikan segar dan bumbu-bumbuan. Kenaikan harga ikan ekor kuning, ikan kembung, bawang-bawangan mendorong semakin tinggi inflasi bahan makanan selain karena faktor musiman berupa hari raya keagamaan (hari raya natal).

Tahap awal dari pembentukan fungsi transfer multi input adalah proses “*prewhitening*”. Proses *prewhitening* adalah pembentukan deret data yang *white noise* melalui pemodelan time series ARIMA. Asumsi dasar yang harus dipenuhi dalam analisis time series dan pembentukan model ARIMA adalah stasioneritas data, baik dalam varians maupun dalam rata-rata.



Gambar 4.14 Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi, (b) Tinggi Gelombang Setelah Transformasi (akar) (c) Kecepatan Angin Sebelum Transformasi (d) Kecepatan Angin Setelah Transformasi (akar)

Gambar 4.14 (a) dan (c) masing-masing menunjukkan bahwa data tinggi gelombang dan kecepatan angin di Kota Jayapura masing belum stasioner dalam varians, dengan ditandai nilai $\lambda \neq 1.0$. Setelah deret data ditransformasi menggunakan jenis transformasi akar, nilai λ pada Gambar 4.14 (b) dan (d) telah menunjukkan bahwa data telah stasioner dalam varians. Pola time series data tinggi gelombang yang *sinusiodal* menyebabkan perlunya proses *differencing* dalam musiman. Sehingga setelah data tinggi gelombang di *differencing* musiman, plot ACF dan PACF pada masing-masing data input telah menunjukkan *cut off* pada lag tertentu, sehingga dapat diambil kesimpulan bahwa data telah stasioner dalam mean. Penentuan orde pada ARIMA tinggi gelombang dan kecepatan angin di Kota Jayapura dapat melalui identifikasi lag signifikan pada plot ACF maupun PACF yang telah stasioner dalam mean dan varians.



Gambar 4.15 Plot ACF (a) PACF (b) Tinggi Gelombang, Plot ACF (c) PACF (d) Kecepatan Angin dan Plot ACF (e) PACF (f) Kecepatan Angin hasil *differencing* musiman di Kota Jayapura

Gambar 4.15 plot ACF data tinggi gelombang yang telah stasioner (a) menunjukkan lag musiman *cutt off* pada lag 12 dan lag non musiman *cutt off* pada lag 5. Plot PACF (b) menunjukkan tidak ada lag yang signifikan pada lag musiman dan *cutt off* pada lag non musiman yaitu 5, 8. Dengan melihat pola ACF dan PACF tersebut dugaan model ARIMA sementara yang terbentuk yaitu $ARIMA ([5],0,0)(0,1,1)^{12}$. Adapun plot ACF kecepatan angin yang telah stasioner

tanpa *differencing* (c) menunjukkan *cutt off* pada lag 1. Plot PACF kecepatan angin yang telah stasioner (d) menunjukkan *cutt off* pada lag 1 dan 11. Model dugaan ARIMA kecepatan angin yaitu ARIMA (1,0,0). Suatu fungsi transfer dengan dua deret input metrik harus memiliki orde *differencing* yang sama. Sehingga, input kecepatan angin akan di-*differencing* sesuai dengan orde *differencing* input tinggi gelombang sebagai orde *differencing* tertinggi. Plot ACF hasil *differencing* input kecepatan angin (e) *cutt off* pada lag 12 dan *dies down* pada lag non musiman. Plot PACF kecepatan angin (f) menunjukkan lag musiman *cut off* pada lag 12 dan lag non musiman *cut off* setelah lag 2. Sehingga, model dugaan ARIMA kecepatan angin yaitu ARIMA (1,0,0)(1,1,0)¹².

Prosedur selanjutnya yaitu mengestimasi parameter dari model deret input yang terbentuk. Tabel 4.14 menunjukkan bahwa parameter model ARIMA tinggi gelombang ([5],0,0)(0,1,1)¹², kecepatan angin yang tidak di *differencing* (1,0,0) dan kecepatan angin yang di-*differencing* (1,0,0)(1,1,0)¹² signifikan pada taraf $\alpha = 0,05$ dengan *p-value* yang kurang dari 0,05.

Tabel 4.14 Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Jayapura

Model ARIMA	Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
([5],0,0)(0,1,1) ¹²	Θ_1	0,798	0,227	3,5	0,0005
	ϕ_5	-0,277	0,109	0,011	0,0113
(1,0,0)	μ	1,264	0,052	24,43	<0,0001
	ϕ_1	0,335	0,104	3,22	0,0013
(1,0,0)(1,1,0) ¹²	ϕ_1	0,35	0,11	3,21	0,0013
	Φ_1	-0,61	0,10	-6,17	<0,0001

Prosedur kelayakan model ARIMA dapat menggunakan uji Ljung-Box, suatu uji untuk mengetahui apakah residual model telah *white noise*. Berdasarkan Tabel 4.15 uji residual untuk model ARIMA ([5],0,0)(0,1,1)¹², ARIMA (1,0,0) dan ARIMA (1,0,0)(1,1,0)¹² pada taraf signifikansi $\alpha = 5\%$ sudah memenuhi asumsi residual *white noise* karena *p-value* > 0,05. Dengan demikian, model ARIMA tersebut dapat digunakan dalam model *prewhitening*.

Tabel 4.15 Uji Residual Model ARIMA $([5],0,0)(0,1,1)^{12}$, ARIMA $(1,0,0)$,
ARIMA $(1,0,0)(1,1,0)^{12}$

Model ARIMA	Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
$([5],0,0)(0,1,1)^{12}$	6	3,29	4	0,511
	12	9,31	10	0,503
	18	14,86	16	0,535
	24	17,46	22	0,738
$(1,0,0)$	6	1,51	5	0,91
	12	11,35	11	0,41
	18	13,46	17	0,705
	24	25,450	23	0,328
$(1,0,0)(1,1,0)^{12}$	6	4,36	4	0,359
	12	13,18	10	0,214
	18	15,37	16	0,498
	24	29,7	22	0,126

Berdasarkan nilai estimasi parameter pada Tabel 4.15 model ARIMA yang terbentuk untuk deret input tinggi gelombang yaitu :

$$(1 + 0,277B^5)(1 - B^{12})x_{11,t} = (1 - 0,798B^{12})\alpha_{11,t},$$

model ARIMA untuk deret input kecepatan angin tanpa *differencing* yaitu :

$$(1 - 0,331B)x_{21,t} = 1,266 + \alpha_{21,t},$$

dan model ARIMA untuk deret input kecepatan angin dengan *differencing* yaitu :

$$(1 - 0,354B)(1 + 0,608B^{12})(1 - B^{12})x'_{21,t} = \alpha'_{21,t}.$$

Sehingga deret input tinggi gelombang, kecepatan angin tanpa *differencing* dan kecepatan angin dengan *differencing* yang telah di-*prewhitening* masing-masing sebagai berikut:

$$\alpha_{11,t} = \frac{(1+0,277B^5)(1-B^{12})}{(1-0,798B^{12})} x_{11,t},$$

$$\alpha_{21,t} = (1 - 0,335B)x_{21,t} - 1,264,$$

dan

$$\alpha'_{21,t} = (1 - 0,354B)(1 + 0,608B^{12})(1 - B^{12})x'_{21,t}.$$

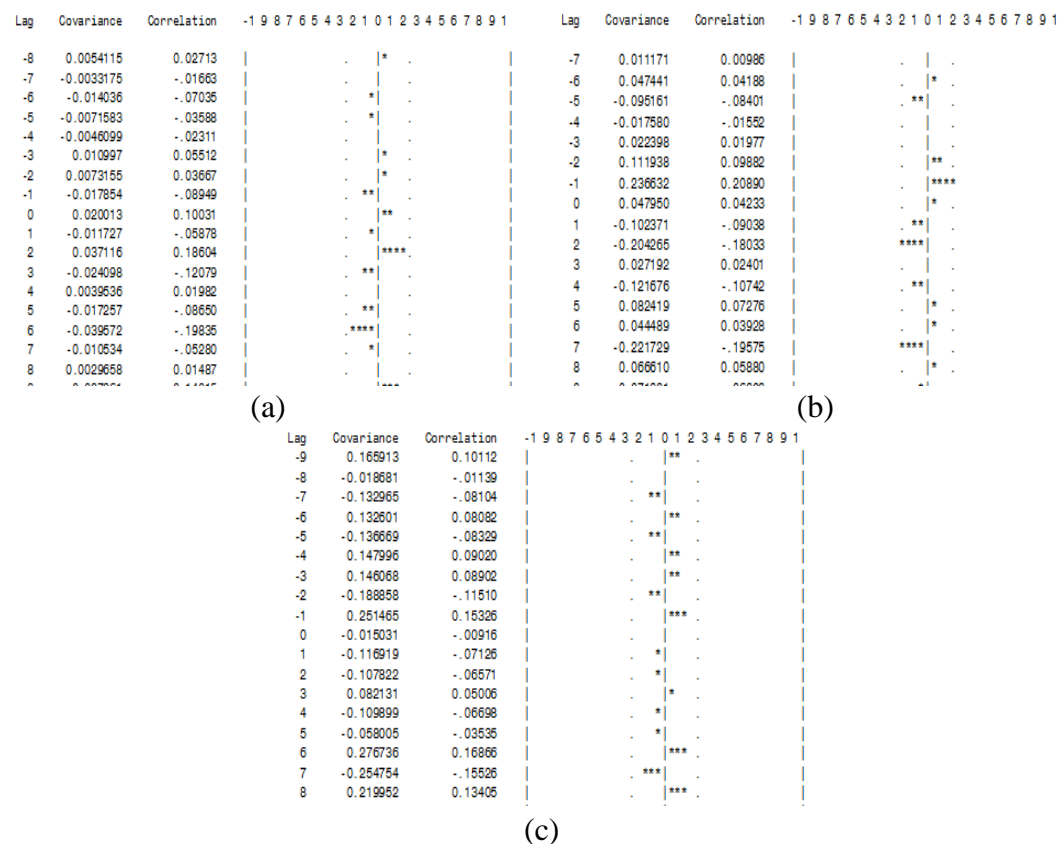
Prewhitening deret output (inflasi bahan makanan Kota Jayapura) mengikuti *prewhitening* masing-masing deret input. Sehingga deret output yang telah di-*prewhitening* dengan masing-masing input yaitu :

$$\beta_{11,t} = \frac{(1+0,277B^5)(1-B^{12})}{(1-0,798B^{12})} y_{11,t},$$

$$\beta_{21,t} = (1 - 0,335B)y_{21,t} - 1,264 ,$$

dan

$$\beta'_{21,t} = (1 - 0,354B)(1 + 0,608B^{12})(1 - B^{12})y'_{21,t}.$$



Gambar 4.16 Plot Crosscorrelation antara deret (a) input Tinggi Gelombang, (b) Kecepatan Angin tanpa Differencing Musiman, (c) Kecepatan Angin dengan Differencing Musiman di Kota Jayapura

Setelah diperoleh deret input dan deret output yang telah di-*prewhitening* untuk masing-masing input, selanjutnya dilakukan identifikasi model dugaan awal dari fungsi transfer single input. Identifikasi didasarkan pada nilai korelasi silang antara masing-masing deret input yang telah di-*prewhitening*. Dari identifikasi tersebut akan diperoleh dugaan kapan, berapa lama deret input mempengaruhi

deret output. Identifikasi tersebut digunakan untuk menentukan orde fungsi transfer (b, r, s).

Plot *Crosscorrelation* antara inflasi bahan makanan dan masing-masing deret input dapat dilihat pada Gambar 4.16. Deret input tinggi gelombang memiliki nilai korelasi silang yang signifikan pada lag 2 dan 6. Sehingga dilakukan pendugaan nilai $b=2$, $s=0$, $r=0$ untuk model awal fungsi transfer tinggi gelombang di Kota Jayapura. Adapun deret input kecepatan angin tanpa *differencing* memiliki nilai korelasi silang yang signifikan pada lag 2. Orde awal dugaan model fungsi transfer dari deret input kecepatan angin tanpa *differencing* yaitu $b=2$, $s=0$, $r=0$. Sedangkan, deret input kecepatan angin dengan *differencing* memiliki nilai korelasi silang yang signifikan pada lag 6. Dengan demikian, orde awal dugaan model fungsi transfer dari deret input kecepatan angin dengan *differencing* yaitu $b=6$, $s=1$, $r=0$.

Hasil estimasi parameter model awal fungsi transfer single input inflasi bahan makanan di Kota Jayapura disajikan pada Tabel 4.16. Hasil estimasi menunjukkan bahwa deret input kecepatan angin tanpa *differencing* signifikan pada $\alpha = 5\%$ dengan $p\text{-value} < 0,05$. Oleh karena itu pada pemodelan fungsi transfer berikutnya hanya menggunakan variabel input kecepatan angin tanpa *differencing* pada data inflasi bahan makanan di Kota Manokwari. Orde $b=2$ menunjukkan bahwa kecepatan angin mempengaruhi inflasi bahan makanan pada periode $t + 2$.

Tabel 4.16 Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Jayapura

Deret Input	Orde	Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
Tinggi Gelombang	(2,0,0)	ω_2	7,194	8,247	0,870	0,383
Kec.Angin	(2,0,0)	μ_{21}	3,324	1,345	2,470	0,014
		ω_2	-2,215	1,030	-2,150	0,031
Kec. Angin Diff	(6,1,0)	ω_6	1,814	1,149	1,580	0,115
		ω_7	1,374	1,136	1,210	0,226


Pengujian residual model dugaan awal kecepatan angin terhadap inflasi bahan makanan di sajikan pada Tabel 4.17. Output uji Ljunkt-Box menunjukkan

bahwa model fungsi transfer dengan orde ($b=2$, $s=0$, $r=0$) menunjukkan adanya autokorelasi pada residual dengan $p\text{-value} < 0,05$ dari lag 13 sampai dengan lag ke-24. Sehingga dapat disimpulkan bahwa model belum memenuhi asumsi *white noise*. Langkah selanjutnya adalah menyelesaikan permasalahan asumsi *white noise* dengan memodelkan residual. Pemodelan residual menggunakan plot ACF dan PACF seperti pada Tabel 4.17.

Tabel 4.17 Hasil Uji Residual *White Noise* Model Awal Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin

Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
6	11,44	6	0,076
12	19,86	12	0,070
18	29,24	18	0,046
24	37,29	24	0,041

Berdasarkan plot ACF dan PACF pada Gambar 4.17 diperoleh lag yang signifikan terletak pada lag ke-1, sehingga model ARIMA yang akan digunakan adalah ARIMA (1,0,0). Hasil estimasi parameter setelah menambahkan pemodelan residual dapat terlihat pada Tabel 4.18 Hasil estimasi parameter pada Tabel 4.18 dengan taraf signifikansi $\alpha = 5\%$ menunjukkan bahwa seluruh parameter signifikan karena $p\text{-value} < 0,05$, sehingga layak digunakan dalam pemodelan.



Gambar 4.17 Plot (a) ACF dan (b) PACF Residual Hasil Pemodelan Fungsi Transfer Sementara Data Input Kecepatan Angin Kota Jayapura

Tabel 4.18 Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Bahan Makanan di Kota Jayapura

Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
μ_{21}	3,401	1,103	3,080	0,002
ϕ_1	-0,334	0,112	-2,980	0,003
ω_2	-2,299	0,851	-2,700	0,007

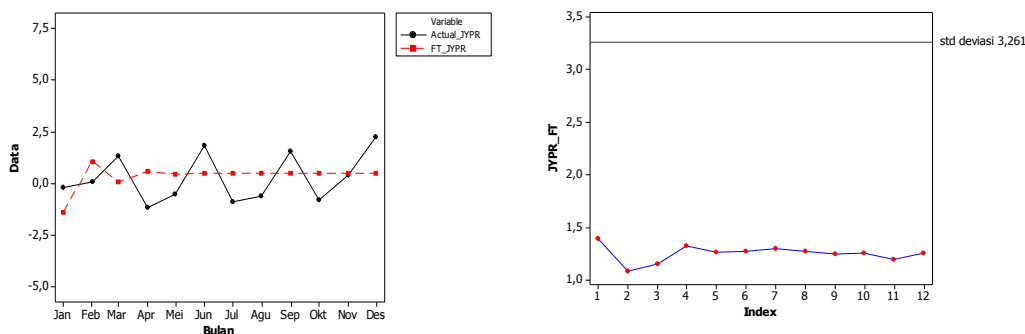
Pengujian asumsi *white noise* kembali dilakukan setelah memodelkan residual fungsi transfer inflasi bahan makanan. Output pengujian asumsi *white noise* dapat dilihat pada Tabel 4.19, menunjukkan bahwa autokorelasi residual model fungsi transfer memiliki *p-value* > 0,05 untuk semua lag. Sehingga dapat disimpulkan bahwa asumsi tidak terdapat korelasi antar residual (*white noise*) terpenuhi. Output uji McLeod-Li pada Lampiran 11 kolom 3 menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model fungsi transfer yang terbentuk memiliki varians yang konstan.

Tabel 4.19 Hasil Uji Residual *White Noise* Model Fungsi Transfer Inflasi Bahan Makanan Kota Jayapura

Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
6	5,13	5	0,400
12	17,94	11	0,083
18	22,27	17	0,174
24	32,52	23	0,090

Pengujian asumsi residual normal dapat menggunakan *Kolmogorov-Smirnov*. Hasil uji statistik menunjukkan nilai 0,06 dengan *p-value* > 0,05 sehingga diperoleh kesimpulan bahwa model telah memenuhi asumsi residual normal. Asumsi residual yang *white noise* independent dan identik serta normal menunjukkan model tersebut layak digunakan untuk meramalkan data inflasi. Perbandingan plot time series peramalan model fungsi transfer dengan variabel input kecepatan angin tanpa *differecing* dapat dilihat pada Gambar 4.18. Nilai RMSE yang diperoleh dari hasil peramalan data *out-sample* $k=12$ pada inflasi

bahan makanan di Kota Jayapura sebesar 1,25. Hasil ramalan cenderung konstan bergerak disekitar nilai nol. Namun setelah melihat perbandingan nilai RMSE *out-sample k* ramalan kedepan yang lebih kecil dibandingkan standar deviasi menunjukkan bahwa model cukup baik meramalkan data inflasi.



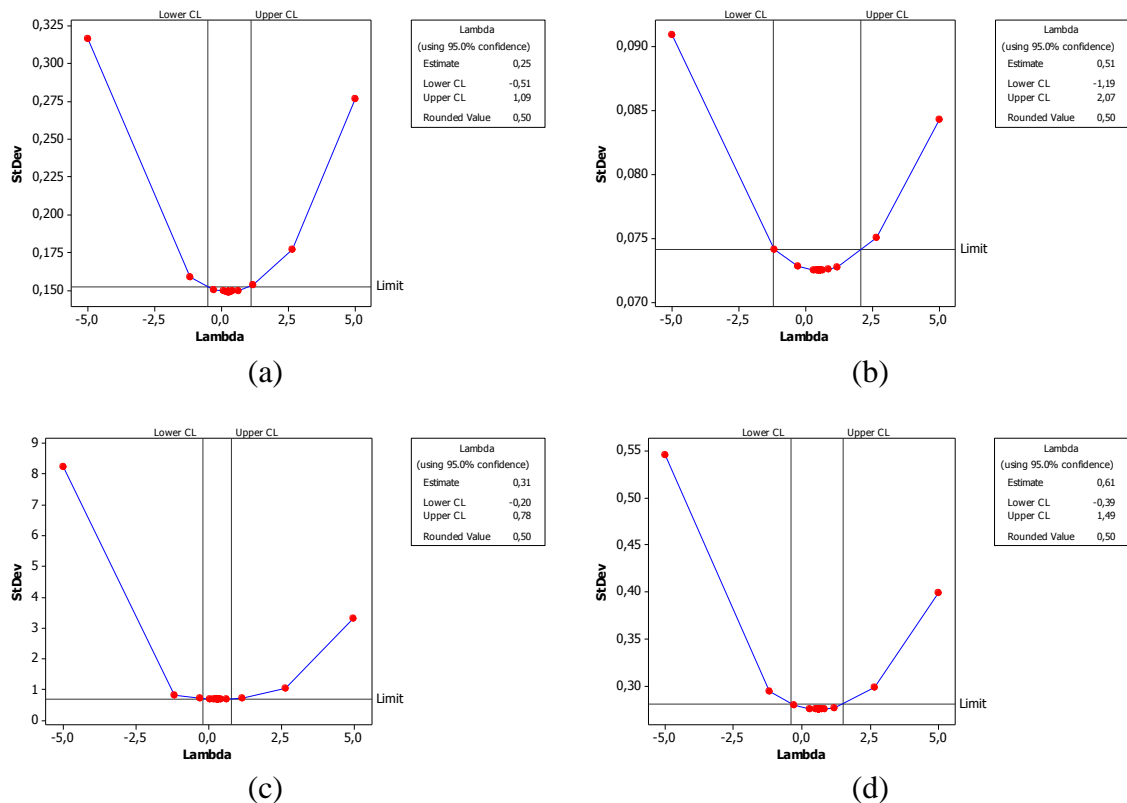
Gambar 4.18 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk *k-step* (kanan) Fungsi Transfer Jayapura

4.3.2. Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Manokwari

Times series plot untuk dua variabel input inflasi bahan makanan di Kota Manokwari menunjukkan pola musiman. Gambar 4.3 dan Gambar 4.4 menunjukkan bahwa pada bulan-bulan tertentu, tinggi gelombang relatif lebih tinggi di sekitar bulan Januari dan Desember dan relatif lebih rendah pada bulan Mei hingga Juli. Sedikit berbeda dengan kondisi kecepatan angin yang cukup berfluktuasi, namun memberikan gambaran bahwa pada penghujung tahun sekitar Desember dan awal Januari, kecepatan angin lebih tinggi dibandingkan dengan bulan-bulan yang lainnya. Kondisi cuaca tersebut menyebabkan relatif tingginya inflasi beberapa sub kelompok inflasi bahan makanan, yaitu inflasi kelompok ikan segar, bumbu-bumbuan dan makanan jadi. Kenaikan harga ikan ekor kuning, ikan kembung, bawang-bawangan mendorong semakin tinggi inflasi bahan makanan selain karena faktor musiman berupa hari raya keagamaan (hari raya natal).

Gambar 4.19 menunjukkan tinggi gelombang (a) dan kecepatan angin (c) masih belum stasioner dalam varians. Sehingga, perlu dilakukan jenis transformasi akar yang disesuaikan dengan nilai $\lambda = 0.5$ pada data yang belum stasioner. Uji Box-Cox *Transformation* dilakukan padaderet data yang telah ditransnformasi. Nilai λ masing-masing pada deret data tinggi gelombang yang telah ditransformasi

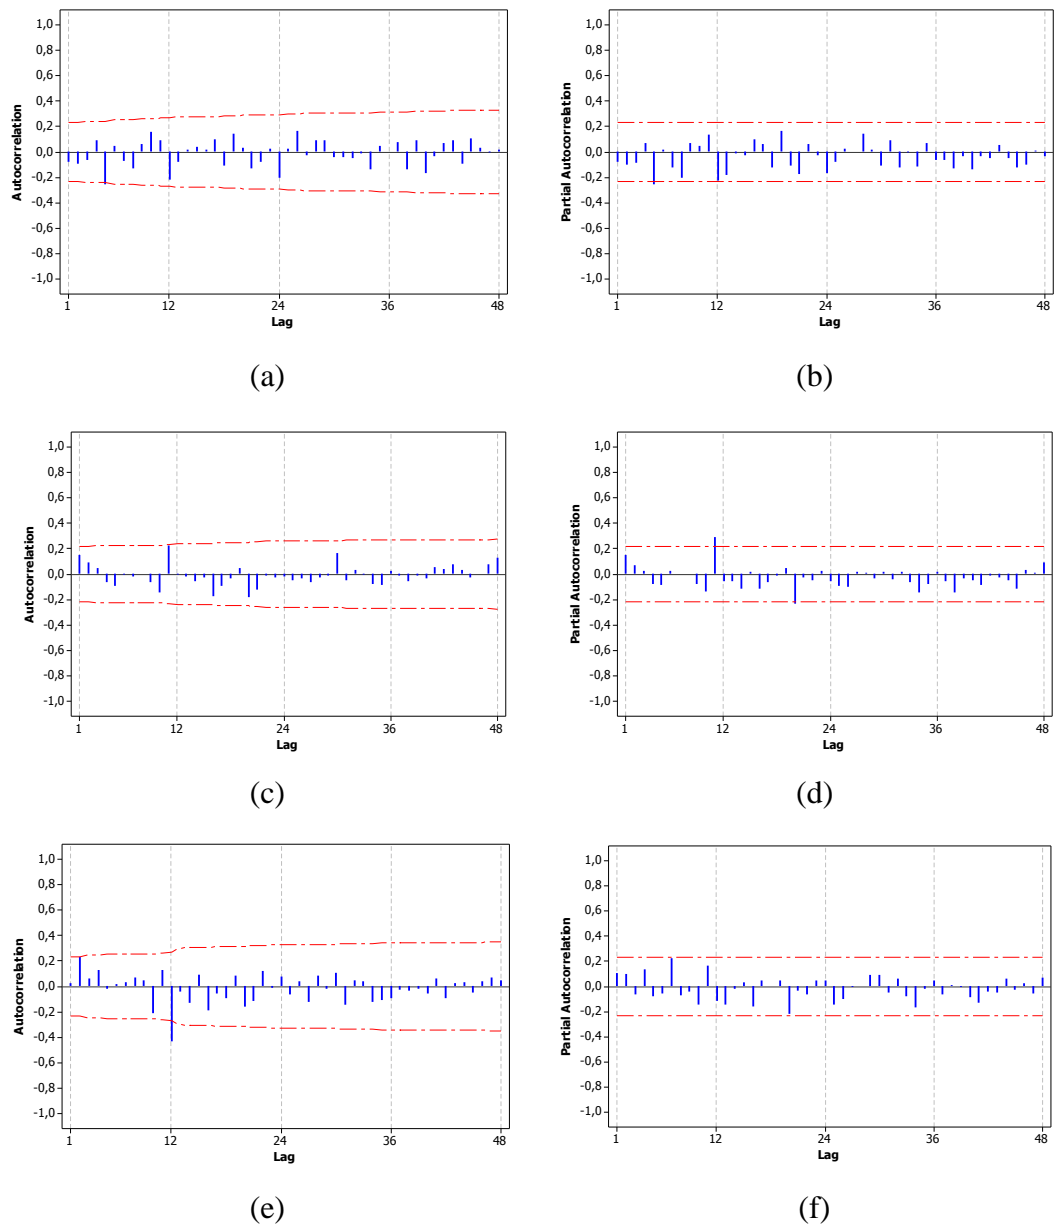
(b) dan kecepatan angin (d) telah berada pada selang nilai *upper* dan *lower* sehingga dapat disimpulkan data telah stasioner dalam varians.



Gambar 4.19 Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi, (b)Tinggi Gelombang Setelah Transformasi (akar), (c) Kecepatan Angin Sebelum Transformasi (d) Kecepatan Angin Setelah Transformasi (akar)

Pola time series data tinggi gelombang di Kota Manokwari sama dengan di Kota Jayapura. Pola plot time series berupa *sinusiodal* menyebabkan perlunya proses *differecing* dalam musiman. Kemudian, prosedur identifikasi stasioner dalam rata-rata dapat dilanjutkan dengan melihat pola plot ACF dan PACF data. Plot ACF dan PACF pada masing-masing data input telah menunjukkan *cut off* pada lag tertentu, sehingga dapat diambil kesimpulan bahwa data telah stasioner dalam rata-rata.

Penentuan orde pada model ARIMA tinggi gelombang dan kecepatan angin di Kota Manokwari dapat melalui identifikasi lag signifikan pada plot ACF maupun PACF. Gambar 4.20 menunjukkan plot ACF dan PACF dari deret data time series.



Gambar 4.20 Plot ACF (a) PACF (b) Tinggi Gelombang, Plot (c) ACF (d) PACF Kecepatan Angin dan Plot (e) ACF (f) PACF Kecepatan Angin hasil *differencing* musiman di Kota Manokwari

Berdasarkan Gambar 4.20, tidak ada lag yang signifikan pada lag musiman dan *cutt off* pada lag 5 di lag non musiman. Plot PACF (b) menunjukan pada lag musiman *cutt off* di lag 12 dan pada lag non musiman *cutt off* pada lag 5. Dengan melihat pola ACF dan PACF tersebut dugaan model ARIMA sementara yang terbentuk yaitu ARIMA $([5],0,0)(1,1,0)^{12}$. Adapun plot ACF (c) dan PACF (d)

kecepatan angin yang telah stasioner menunjukkan signifikansi di lag 11. Sehingga. Model ARIMA sementara kecepatan angin di Manokwari yaitu $([11],0,0)$.

Sama halnya dengan pembentukan model fungsi transfer multi input di Kota Jayapura, pembentukan model fungsi transfer multi input di Kota Manokwari mengharuskan proses *differencing* pada input kecepatan angin. Sehingga plot ACF kecepatan angin hasil *differencing* (e) menunjukkan lag musiman *dies down* serta *cutt off* pada lag non musiman yaitu lag 2. Plot PACF-nya (d) menunjukkan lag musiman *cutt off* pada lag 12 demikian juga pola *cutt off* pada lag non musiman yaitu lag 2 dan 10. Signifikansi lag pada pola ACF dan PACF memberikan beberapa kemungkinan model ARIMA, diantaranya model dugaan ARIMA kecepatan angin yaitu ARIMA $(1,1,0)^{12}$.

Prosedur selanjutnya yaitu mengestimasi parameter dari model deret input yang terbentuk. Tabel 4.20 menunjukkan bahwa seluruh parameter model ARIMA deret input signifikan pada taraf $\alpha = 5\%$ dengan *p-value* yang kurang dari 0,05. Sehingga seluruh parameter model ARIMA dapat digunakan dalam model.

Tabel 4.20 Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Manokwari

Model ARIMA	Parameter	Estimasi	Standar error	<i>t-value</i>	<i>p-value</i>
$([5],0,0)(1,1,0)^{12}$	ϕ_5	-0,273	0,12	-2,34	0,0193
	Φ_1	-0,307	0,12	-2,47	0,0137
$([11],0,0)$	μ	1,276	0,041	31,240	<0,0001
	ϕ_{11}	0,283	0,119	2,370	0,0200
$(1,1,0)^{12}$	Φ_1	-0,496	0,109	-4,560	<0,0001

Demikian juga pengujian asumsi residual *white noise* dan normal, semua model ARIMA, baik ARIMA $([5],0,0)(1,1,0)^{12}$, ARIMA $([11],0,0)$, ARIMA $(1,1,0)^{12}$ telah memenuhi asumsi. Sehingga model ARIMA tersebut dapat digunakan dalam tahapan *prewhitening* deret input maupun deret output.

Berdasarkan nilai estimasi parameter pada Tabel 4.20 model ARIMA yang terbentuk untuk deret input tinggi gelombang di Kota Manokwari yaitu :

$$(1 + 0,277B^5)(1 + 0,307B^{12})(1 - B^{12})x_{12,t} = \alpha_{12,t}.$$

Model ARIMA untuk deret input kecepatan angin tanpa *differencing* yaitu :

$$(1 - 0,283B^{11})x_{22,t} = 1,28 + \alpha_{22,t}.$$

Model ARIMA untuk deret input kecepatan angin dengan *differencing* yaitu :

$$(1 + 0,496B^{12})(1 - B^{12})x'_{22,t} = \alpha'_{22,t}.$$

Sehingga deret input tinggi gelombang dan kecepatan angin yang telah di-*prewhitening* masing-masing adalah :

$$\alpha_{12,t} = (1 + 0,277B^5)(1 + 0,307B^{12})(1 - B^{12})x_{12,t},$$

$$\alpha_{22,t} = (1 - 0,283B^{11})x_{22,t} - 1,28 \text{ dan}$$

$$\alpha'_{22,t} = (1 + 0,496B^{12})(1 - B^{12})x'_{22,t}.$$

Sehingga *prewhitening* deret output (inflasi bahan makanan Kota Manokwari) mengikuti *prewhitening* masing-masing deret input, yaitu deret output yang telah di-*prewhitening* dengan input tinggi gelombang yaitu :

$$\beta_{12,t} = (1 + 0,277B^5)(1 + 0,307B^{12})(1 - B^{12})y_{12,t}.$$

Deret output yang telah di-*prewhitening* dengan input kecepatan angin tanpa *differencing* yaitu :

$$\beta_{22,t} = (1 - 0,283B^{11})y_{22,t} - 1,28.$$

Deret output yang telah di-*prewhitening* input kecepatan angin dengan *differencing* yaitu :

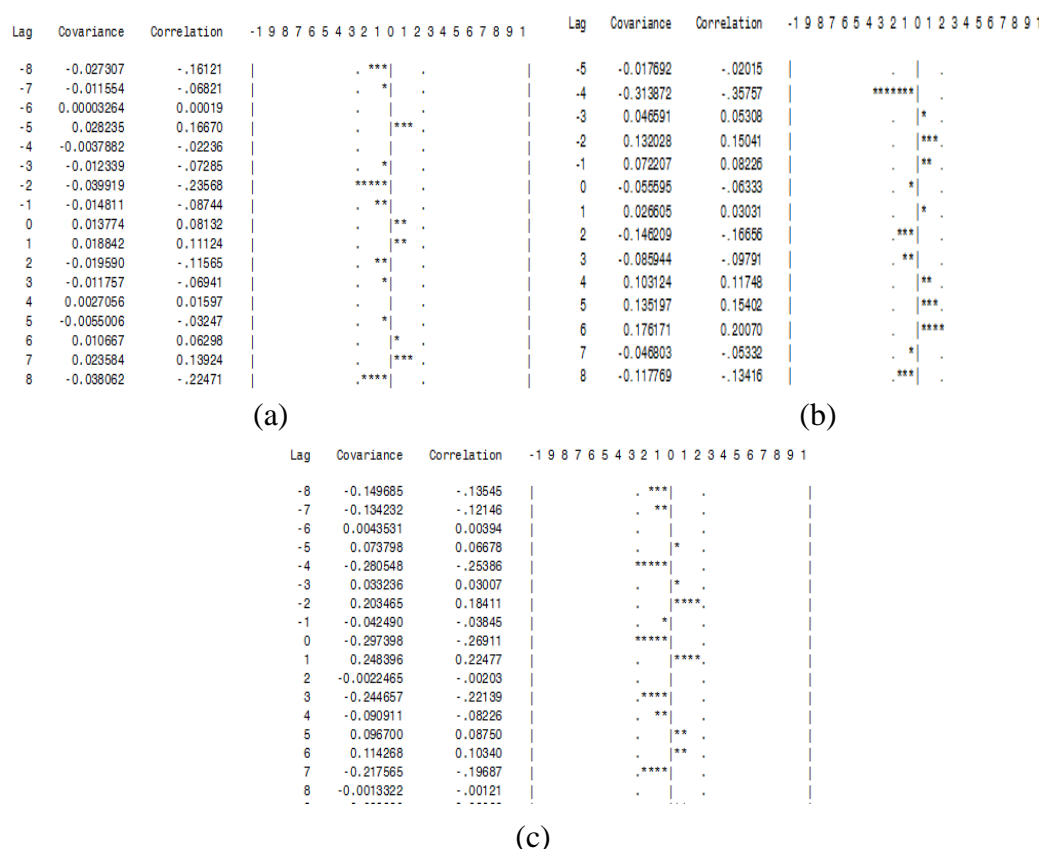
$$\beta'_{22,t} = (1 + 0,496B^{12})(1 - B^{12})y'_{22,t}.$$

Tabel 4.21 Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Manokwari

Deret Input	Orde	Parameter	Estimasi	Standar error	t-value	p-value
Tinggi Gelombang	(8,0,0)	ω_2	-22,748	7,337	-3,100	0,002
Kec.Angin	(6,0,0)	ω_6	0,566	0,259	2,190	0,029
Kec. Angin Diff	(0,1,0)	ω_0	-2,371	1,064	-2,230	0,026
		ω_1	-1,883	1,049	-1,800	0,073

Penentuan orde fungsi transfer pada masing-masing deret input dapat menggunakan plot *Crosscorrelation*. Gambar 4.21 menunjukkan orde dugaan awal fungsi transfer deret input tinggi gelombang, kecepatan angin tanpa *differencing*,

kecepatan angin dengan *differencing* masing-masing ($b=8, s=0, r=0$), ($b=6, s=0, r=0$), ($b=0, s=1, r=0$). Dugaan awal bahwa faktor cuaca pertama kali mempengaruhi inflasi saat $t+8$, $t+6$ atau saat itu juga.



Gambar 4.21 Plot *Crosscorrelation* antara (a) deret input Tinggi Gelombang, (b) Kecepatan Angin tanpa *Differencing* Musiman, (c) Kecepatan Angin dengan *Differencing* Musiman di Kota Manokwari

Hasil estimasi parameter model awal fungsi transfer masing-masing input dapat dilihat pada Tabel 4.21. Seluruh parameter signifikan pada $\alpha = 10\%$ dengan $p\text{-value} < 0,05$. Pemilihan model fungsi transfer terbaik yang mampu menjelaskan inflasi bahan makanan di Kota Manokwari dapat dilakukan setelah membentuk fungsi transfer multi input. Sehingga, prosedur selanjutnya adalah melakukan pembentukan model fungsi transfer multi input menggunakan data tinggi gelombang dan kecepatan angin yang telah di-*differencing*.

Estimasi parameter model fungsi transfer multi input dapat dilihat pada Tabel 4.22. Parameter input kecepatan angin hasil *differencing* tidak signifikan pada $\alpha = 10\%$ dengan $p\text{-value} < 0,05$. Berdasarkan output tersebut dapat

disimpulkan bahwa model fungsi transfer multi input tidak dapat dimodelkan secara bersama-sama menggunakan input tinggi gelombang dan kecepatan angin hasil *differencing*. Hal ini diduga karena kedua input tersebut saling berkorelasi. Dengan demikian, inflasi bahan makanan hanya dapat memiliki model fungsi transfer single input.

Tabel 4.22 Hasil Estimasi Parameter Model Awal Fungsi Transfer Multi Input Inflasi Bahan Makanan Kota Manokwari

Deret Input	Orde	Parameter	Estimasi	Standar error	t-value	p-value
Tinggi Gelombang	(8,0,0)	ω_2	-19,789	7,365	-2,690	0,007
Kec. Angin Diff	(0,1,0)	ω_0	-1,698	1,023	-1,660	0,097
		ω_1	-1,358	1,017	-1,340	0,182

Pemilihan model fungsi transfer single input terbaik dapat dilakukan dengan membandingkan nilai RMSE terkecil pada masing-masing model berdasarkan nilai standar deviasi data *in-sample* (3,06). Tabel 4.23 menunjukkan bahwa input dengan model fungsi transfer terbaik adalah kecepatan angin. Sehingga pemodelan fungsi transfer berikutnya hanya menggunakan variable input kecepatan angin terhadap data inflasi bahan makanan di Kota Manokwari.

Tabel 4.23 Nilai RMSE *in-sample* Fungsi Transfer antar Deret Input

Input	Orde	RMSE
Tinggi Gelombang	(8,0,0)	3,30
Kec.Angin	(6,0,0)	2,99
Kec. Angin Diff	(0,1,0)	3,49


Pengujian residual model fungsi transfer dugaan awal kecepatan angin terhadap inflasi bahan makanan di sajikan pada Tabel 4.24. Output uji Ljung-Box menunjukkan bahwa model fungsi transfer dengan orde ($b=6$, $s=0$, $r=0$) menunjukkan sudah tidak adanya autokorelasi antar residual lag dengan $p\text{-value} > 0,05$. Sehingga dapat disimpulkan bahwa model telah memenuhi asumsi *white*

noise. Output uji McLeod-Li pada Lampiran 11 kolom 5 menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model ARIMA yang terbentuk memiliki varians yang konstan. Hasil pengujian asumsi residual normal menggunakan *Kolmogorov-Smirnov* menunjukkan nilai 0,095 dengan *p-value* > 0,05 sehingga diperoleh kesimpulan bahwa model telah memenuhi asumsi residual normal.

Tabel 4.24 Hasil Uji Residual *White Noise* Model Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin

Lag	<i>Chi-Square</i>	DF	<i>p-value</i>
6	10,77	6	0,096
12	18,62	12	0,098
18	23,69	18	0,166
24	36,06	24	0,054

Perbandingan hasil peramalan model fungsi transfer dengan variabel input kecepatan angin tanpa *differencing* dapat dilihat pada Gambar 4.22. Hasil peramalan yang konstan menunjukkan model kurang dapat meramalkan aktual *out-sample* yang fluktuatif di Manokwari. Model yang terbentuk hanya mampu meramal hingga $k=11$ waktu ke depan. Peramalan setelahnya menghasilkan hasil yang kurang baik karena nilai RMSE *out-sample* yang lebih besar dari standar deviasi.




Gambar 4.22 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk *k-step* (kanan) Fungsi Transfer Manokwari

4.3.3. Fungsi Transfer Multi Input Inflasi Bahan Makanan di Kota Sorong

Berdasarkan time series plot untuk dua variabel input inflasi bahan makanan di Kota Sorong, tercatat pola yang berulang pada bulan tertentu sehingga diduga deret data tersebut mengandung unsur musiman. Gambar 4.3 dan Gambar 4.4 menunjukkan tinggi gelombang relatif lebih tinggi di sekitar akhir tahun (bulan Desember dan awal bulan Januari) dan pertengahan tahun (bulan Juli dan Agustus). Meskipun pola tinggi gelombang pada pertengahan tahun tidak lebih tinggi jika dibandingkan tinggi gelombang di akhir tahun.


Sedikit berbeda dengan kondisi kecepatan angin, dimana kecepatan angin dengan knot tertinggi terjadi pada pertengahan tahun, yaitu bulan Juni hingga Desember. Kondisi cuaca tersebut menyebabkan relatif tingginya inflasi beberapa sub kelompok inflasi bahan makanan, yaitu inflasi kelompok ikan segar, bumbu-bumbuan dan makanan jadi. Kenaikan harga ikan ekor kuning, ikan kembung, bawang-bawangan mendorong semakin tinggi inflasi bahan makanan selain karena faktor musiman berupa hari raya keagamaan (hari raya natal).

Tahapan pembentukan fungsi transfer multi input pada inflasi bahan makanan di Kota Sorong sama dengan prosedur fungsi transfer pada umumnya yaitu mensyaratkan deret data time series stasioner dalam varian dan rata-rata. Gambar 4.23 menunjukkan tinggi gelombang (a) dan kecepatan angin (c) masih belum stasioner dalam varians. Sehingga, perlu dilakukan jenis transformasi yang sesuai. Jenis transformasi untuk data tinggi gelombang adalah Logaritma Natural (Ln) karena nilai $\lambda = 0.0$. Sedangkan jenis transformasi untuk data kecepatan angin adalah akar karena nilai $\lambda = 0.5$.




Gambar 4.23 Plot Box Cox (a) Data Tinggi Gelombang Sebelum Transformasi
(b) Kecepatan Angin Sebelum Transformasi


Pola plot time series data tinggi gelombang di Kota Sorong menyebabkan data perlu di *differencing* musiman. Plot ACF dan PACf pada masing-masing deret input telah *cut off* hanya muncul pada lag-lag tertentu, sehingga dapat disimpulkan data telah stasioner dalam rata-rata. Dengan demikian, prosedur pembentukan model fungsi transfer single input dapat dilanjutkan dengan penentuan orde model ARIMA masing-masing deret input.




(a)




(b)




(c)



(d)



(e)



(f)

Gambar 4.24 Plot (a) ACF (b) PACF Tinggi Gelombang, Plot (c) ACF (d) PACF Kecepatan Angin dan Plot (e) ACF (f) PACF Kecepatan Angin hasil *differencing* musiman di Kota Sorong

Penentuan orde pada model ARIMA tinggi gelombang dan kecepatan angin di Kota Sorong dapat melalui identifikasi lag signifikan pada plot ACF maupun PACF. Gambar 4.23 plot ACF data tinggi gelombang yang telah stasioner (a) menunjukkan *dies down* pada lag musiman serta pola *cutt off* pada lag 3 dan 10 di lag non musiman. Plot PACF (b) menunjukkan pola *cutt off* baik di lag musiman maupun non musiman, masing-masing lag 12 dan lag 1. Dengan melihat pola ACF dan PACF tersebut dugaan model ARIMA sementara yang terbentuk yaitu ARIMA $([1,12],0,[3,10])(0,1,0)^{12}$.

Adapun plot ACF kecepatan angin tanpa *differencing* (c) menunjukkan pola *dies down* dan *cutt off* pada lag 1,2,5,7,8 plot PACF (d). Dengan demikian, model dugaan ARIMA kecepatan angin tanpa *differencing* yaitu ARIMA $([1,9],0,0)(1,0,0)^{12}$. Adapun plot PACF data kecepatan angin hasil *differencing* menunjukkan *cutt off* pada lag musiman dan *dies down* pada lag non musiman. Plot PACF (d) menunjukkan tidak ada lag yang signifikan pada lag musiman dan lag non musiman *cut off* setelah lag 1 dan 8. Dengan demikian, model dugaan ARIMA kecepatan angin yaitu ARIMA $(1,0,0)(0,1,1)^{12}$.

Tabel 4.25 Hasil Estimasi Parameter Model ARIMA Deret Input Tinggi Gelombang dan Kecepatan Angin Kota Sorong

Model ARIMA	Parameter	Estimasi	Standar error	t-value	p-value
$([1,12],0,[3,10])(0,1,0)^{12}$	θ_3	-0,300	0,116	-2,58	0,0099
	θ_{10}	0,274	0,126	2,18	0,0295
	ϕ_1	0,354	0,103	3,43	0,0006
	ϕ_{12}	-0,314	0,110	-2,87	0,0042
$([1,9],0,0)(1,0,0)^{12}$	μ	1,548	0,065	23,670	<0,0001
	ϕ_1	0,490	0,090	5,460	<0,0001
	ϕ_9	-0,322	0,091	-3,560	0,0004
	Φ_1	0,510	0,107	4,760	<0,0001
$(1,0,0)(0,1,1)^{12}$	Θ_1	0,795	0,232	3,43	0,0006
	ϕ_1	0,535	0,094	5,67	<0,0001

Prosedur selanjutnya yaitu mengestimasi parameter dari model deret input yang terbentuk. Tabel 4.25 menunjukkan bahwa seluruh parameter signifikan pada

$\alpha = 5\%$. Berdasarkan Tabel 4.26 residual untuk seluruh model ARIMA pada taraf signifikansi $\alpha = 5\%$ sudah memenuhi asumsi residual *white noise* karena *p-value* $> 0,05$. Sehingga, model ARIMA tersebut dapat dilanjutkan dengan tahapan fungsi transfer.

Berdasarkan nilai estimasi parameter pada Tabel 4.25 model ARIMA yang terbentuk untuk deret input tinggi gelombang di Kota Sorong yaitu :

$$(1 - 0,354B^1 + 0,314B^{12})(1 - B^{12})x_{13,t} = (1 + 0,3B^3 - 0,273B^{10})\alpha_{13,t}.$$

Model ARIMA untuk deret input kecepatan angin tanpa *differencing* yaitu :

$$(1 - 0,491B + 0,328B^9)(1 - 0,498B^{12})x_{23,t} = 1,549 + \alpha_{23,t}.$$

Sedangkan model ARIMA untuk deret input kecepatan angin dengan *differencing* yaitu :

$$(1 - 0,535B^1)(1 - B^{12})x'_{23,t} = (1 - 0,795B^{12})\alpha'_{23,t}.$$

Tabel 4.26 Uji Residual Model ARIMA ([1,12],0,[9]) untuk Tinggi Gelombang dan ARIMA ([1,9],0,0)(1,0,0)¹² untuk Kecepatan Angin Kota Sorong

Model ARIMA	Lag	Chi-Square	DF	p-value
([1,12],0,[3,10]) (0,1,0) ¹²	6	4,42	3	0,220
	12	16,46	9	0,058
	18	23	15	0,076
	24	29	21	0,108
([1,9],0,0)(1,0,0) ¹²	6	4,09	3	0,252
	12	9,77	9	0,369
	18	14,50	15	0,488
	24	15,64	21	0,790
(1,0,0)(0,1,1) ¹²	6	3,88	4	0,422
	12	11,77	10	0,301
	18	15,14	16	0,515
	24	18	22	0,706

Sehingga deret input tinggi gelombang dan kecepatan angin yang telah di-*prewhitening* masing-masing adalah :

$$\alpha_{13,t} = \frac{(1-0,354B^1+0,314B^{12})(1-B^{12})}{(1+0,3B^3-0,273B^{10})} x_{13,t},$$

$$\alpha_{23,t} = (1 - 0,491B + 0,328B^9)(1 - 0,498B^{12})x_{23,t} - 1,549 \text{ dan}$$

$$\alpha'_{13,t} = \frac{(1-0,535B^1)(1-B^{12})}{(1-0,795B^{12})} x'_{23,t}.$$

Prewhitening deret output (inflasi bahan makanan Kota Sorong) mengikuti *prewhitening* masing-masing deret input. Sehingga deret output yang telah di-*prewhitening* dengan input tinggi gelombang yaitu :

$$\beta_{13,t} = \frac{(1-0,354B^1+0,314B^{12})(1-B^{12})}{(1+0,3B^3-0,273B^{10})} y_{13,t},$$

deret output yang telah di-*prewhitening* dengan input kecepatan angin tanpa *differencing* yaitu :

$$\beta_{23,t} = (1 - 0,491B + 0,328B^9)(1 - 0,498B^{12})y_{23,t} - 1,549,$$

dan deret output yang telah di-*prewhitening* input kecepatan angin dengan *differencing* yaitu :

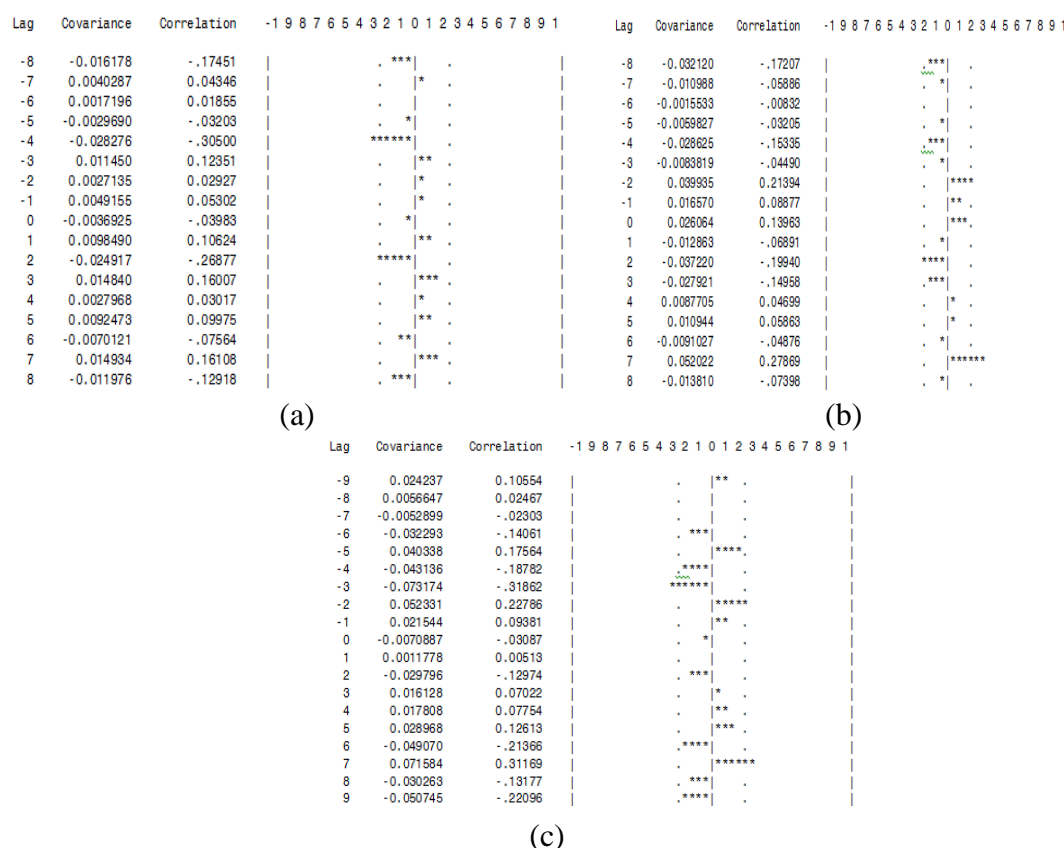
$$\beta'_{13,t} = \frac{(1-0,535B^1)(1-B^{12})}{(1-0,795B^{12})} \beta'_{23,t}.$$

Penentuan orde fungsi transfer pada masing-masing deret input dapat menggunakan plot *Crosscorrelation*. Gambar 4.25 menunjukkan orde dugaan awal fungsi transfer deret input tinggi gelombang, kecepatan angin tanpa *differencing*, kecepatan angin dengan *differencing* masing-masing ($b=2, s=1, r=0$), ($b=0, s=2, r=0$), dan ($b=7, s=0, r=0$).

Tabel 4.27 Hasil Estimasi Parameter Model Awal Fungsi Transfer Single Input Inflasi Bahan Makanan dan Tinggi Gelombang Kota Manokwari

Deret Input	Orde	Parameter	Estimasi	Standar error	t-value	p-value
Tinggi Gelombang	(2,1,0)	ω_2	-1,055	0,491	-2,150	0,032
		ω_3	-0,977	0,491	-1,990	0,047
		μ	2,696	0,306	8,81	<,0001
Kec.Angin	(0,[2],0)	ω_0	0,364	0,138	2,63	0,0085
		ω_2	0,451	0,139	3,24	0,0012
Kec. Angin Diff	(7,0,0)	ω_7	0,470	0,158	2,980	0,003

Hasil estimasi parameter model awal fungsi transfer masing-masing input dapat dilihat pada Tabel 4.27. Seluruh parameter signifikan pada $\alpha = 10\%$ dengan $p\text{-value} < 0,05$. Pemilihan model fungsi transfer terbaik yang mampu menjelaskan inflasi bahan makanan di Kota Sorong dapat dilakukan setelah membentuk fungsi transfer multi input. Sehingga, prosedur selanjutnya adalah melakukan pembentukan model fungsi transfer multi input menggunakan data tinggi gelombang dan kecepatan angin yang telah di-differencing.



Gambar 4.25 Plot Crosscorrelation antara deret input (a) Tinggi Gelombang , (b) Kecepatan Angin tanpa Differencing Musiman, (c) Kecepatan Angin dengan Differencing Musiman di Kota Sorong

Tabel 4.28 Hasil Estimasi Parameter Model Awal Fungsi Transfer Multi Input Inflasi Bahan Makanan Kota Sorong

Deret Input	Orde	Parameter	Estimasi	Standar error	t-value	p-value
Tinggi Gelombang	(2,1,0)	ω_2	-0,845	0,466	-1,81	0,070
		ω_3	-0,751	0,460	-1,63	0,102
Kec. Angin Diff	(0,1,0)	ω_1	0,398	0,160	2,49	0,013

Estimasi parameter model fungsi transfer multi input dapat dilihat pada Tabel 4.28. Parameter input tinggi gelombang tidak signifikan pada $\alpha = 10\%$ dengan $p\text{-value} > 0,1$. Berdasarkan output tersebut dapat disimpulkan bahwa model fungsi transfer multi input tidak dapat dimodelkan secara bersama-sama menggunakan input tinggi gelombang dan kecepatan angin hasil *differencing*. Hal ini diduga karena kedua input tersebut saling berkorelasi. Dengan demikian, inflasi bahan makanan hanya dapat memiliki model fungsi transfer single input.

Tabel 4.29 Nilai RMSE Fungsi Transfer antar Deret Input

Input	Orde	RMSE
Tinggi Gelombang	(2,1,0)	3,16
Kec.Angin	(0,[2],0)	2,74
Kec. Angin <i>Diff</i>	(7,0,0)	2,83

Pemilihan model fungsi transfer single input terbaik dapat dilakukan dengan membandingkan nilai RMSE terkecil pada masing-masing model berdasarkan nilai standar deviasi data *in-sample* (3,08). Tabel 4.29 menunjukkan bahwa input dengan model fungsi transfer terbaik adalah kecepatan angin dengan RMSE *out-sample* terkecil 2,74. Sehingga pemodelan fungsi transfer berikutnya hanya menggunakan variable input kecepatan angin terhadap data inflasi bahan makanan di Kota Sorong.


Tabel 4.30 Hasil Uji Residual *White Noise* Model Fungsi Transfer Inflasi Bahan Makanan dengan Variabel Input Kecepatan Angin

Lag	Chi-Square	DF	p-value
6	11,91	6	0,064
12	15,27	12	0,227
18	22,95	18	0,193
24	26,21	24	0,343

Hasil uji residual yang *white noise* pada Tabel 4.30 menunjukkan bahwa autokorelasi residual model fungsi transfer inflasi bahan makanan Kota Sorong memiliki $p\text{-value}$ yang lebih besar dari 0,05 untuk semua lag yang berarti bahwa

autokorelasi tidak signifikan dengan taraf signifikansi $\alpha = 5\%$ atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi. Sedangkan hasil uji McLeod-Li pada Lampiran 11 kolom 7 menunjukkan *p-value* yang lebih besar dari 0,05 sehingga dapat disimpulkan bahwa residual dari model ARIMA yang terbentuk memiliki varians yang konstan. Uji normalitas Kolmogorow-Smirnow pada residual model fungsi transfer inflasi bahan makanan Kota Sorong menghasilkan nilai uji sebesar 0,078 dan *p-value* lebih besar dari 0,15. Dengan taraf signifikansi $\alpha = 5\%$ dapat disimpulkan bahwa model fungsi transfer inflasi bahan makanan Kota Sorong sudah memenuhi asumsi *white noise* dan normal dengan input kecepatan angin.

Perbandingan hasil peramalan model fungsi transfer dengan variabel input kecepatan angin tanpa *differentiating* dapat dilihat pada Gambar 4.26. Hasil peramalan cukup mendekati nilai aktual *out-sample* terkecuali untuk bulan Juni dan Juli yang sedikit berbeda pola data ditahun sebelumnya. Bulan tersebut bertepatan dengan masuknya bulan ramadhan sehingga secara rata-rata hampir seluruh komoditas pangan mengalami kenaikan. Nilai RMSE untuk k langkah peramalan ke depan telah berada dibawah nilai standar deviasi dan cenderung mengalami kenaikan. Namun secara umum dapat meramalkan dengan baik nilai inflasi di Kota Manokwari



Gambar 4.26 Perbandingan data aktual dan ramalan *out-sample* (kiri) dan nilai RMSE *out-sample* untuk k -step (kanan) Fungsi Transfer Sorong

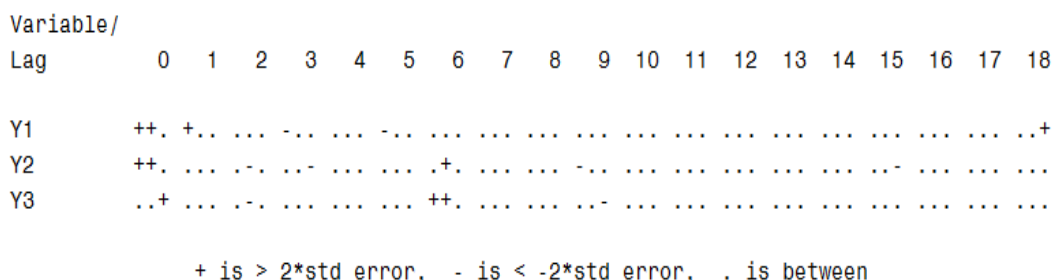
4.4 Pemodelan GSTAR dengan Data Inflasi Tiga Kota di Pulau Papua

Pemodelan GSTAR secara umum serupa dengan prosedur pemodelan Box-Jenkins, yaitu tahap awal dimulai dengan identifikasi meliputi uji stasioneritas data

dan penentuan orde waktu dan spasial (lokasi). Tahapan selanjutnya berupa estimasi parameter dengan berbagai bobot lokasi, tahapan pemeriksaan kelayakan model (*diagnostic checking*) dengan pengujian residual yang *white noise* dan tahapan peramalan.

4.4.1. Identifikasi Model GSTAR

Identifikasi stasioneritas secara multivariat dapat dilakukan secara visual melalui skema MCCF. Hasil pemeriksaan stasioneritas dalam skema MCCF dapat dilihat pada Gambar 4.27. Skema MCCF pada Gambar 4.27 menunjukkan bahwa data inflasi bahan makanan tiga lokasi di Pulau Papua merupakan data yang telah stasioner. Hal ini didasarkan pada skema banyaknya muncul tanda titik (.) dari pada tanda positif (+) dan negatif (-). Identifikasi kestasioneritas secara univariate dan multivariat memberikan kesimpulan yang sama bahwa data inflasi bahan makanan telah stasioner dalam rata-rata tanpa perlu adanya *differencing*.



Gambar 4.27 Representasi Skema MCCF untuk data Inflasi Bahan Makanan di Tiga Lokasi Pulau Papua

Skema MCCF pada lag 0 dapat diinterpretasi sebagai bentuk ketergantungan antar wilayah di waktu yang sama. Gambar 4.27 menunjukkan bahwa inflasi bahan makanan di Kota Manokwari dan Sorong saling mempengaruhi dengan tanda positif namun tidak dengan Kota Jayapura. Kota Manokwari dan Sorong merupakan wilayah penghasil pangan di Provinsi Papua Barat, sehingga jarak yang relatif dekat memungkinkan interaksi pertukaran bahan pangan lebih tinggi dibandingkan dengan Kota Jayapura. Disamping itu, posisi administratif yang berada pada satu provinsi memungkinkan berbagai kebijakan harga pangan yang diterapkan sama. Frekuensi perjalanan kapal laut yang cukup

intens setiap bulannya menyebabkan hubungan ketergantungan antar wilayah terjadi dibulan yang sama.

Tahapan identifikasi model dilanjutkan dengan penentuan orde waktu yang sesuai pada model GSTAR. Penentuan orde waktu dapat dilakukan dengan memperhatikan skema MPCCF. Skema MPCCF menunjukan nilai korelasi parsial dari lag yang berada diluar nilai standar deviasi dengan ditunjukan oleh tanda positif (+) dan negatif (-). Banyaknya tanda (+) dan (-) pada lag tertentu diduga sebagai lag yang sesuai untuk model GSTAR. Hasil skema MPCCF data inflasi bahan makanan dapat dilihat pada Gambar 4.28.

Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
Y1	+-
Y2
Y3

+ is > 2*std error, - is < -2*std error, . is between

Gambar 4.28 Representasi Skema MPCCF untuk data Inflasi Bahan Makanan di Tiga Lokasi Pulau Papua

Berdasarkan Gambar 4.28 lag signifikan pada skema MPCCF menunjukan orde waktu yang digunakan dalam model GSTAR yaitu lag 1 sedangkan orde spasial yang digunakan dibatasi pada orde spasial waktu. Sehingga, model GSTAR yang digunakan dalam pemodelan inflasi bahan makanan di tiga kota pulau papua adalah GSTAR (1₁). Model GSTAR (1₁) dapat ditulias dalam persamaan:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} \phi_{10}^1 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 \\ 0 & 0 & \phi_{30}^1 \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 \\ 0 & 0 & \phi_{31}^1 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{22} \\ w_{31} & w_{32} & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix},$$

dengan $\dot{Y}_{i,t} = Y_{i,t} - \mu_i$; dan μ_i = rata-rata.

4.4.2. Estimasi Parameter Model GSTAR

Estimasi parameter model GSTAR (1₁) dalam pemodelan data inflasi bahan makanan tiga kota di Pulau Papua dilakukan dengan menggunakan estimasi GLS. Metode estimasi ini dipilih karena pada beberapa penelitian sebelumnya

memberikan hasil estimasi parameter dengan varians yang lebih kecil sehingga estimasi yang selanjutnya dinyatakan dengan GSTAR-GLS (1₁).

Penggunaan bobot lokasi pemodelan GSTAR dalam penelitian menggunakan lima macam bobot, yaitu bobot invers jarak yang menggunakan jarak tempuh *riil* transportasi laut, normalisasi korelasi silang dan normalisasi inferensi korelasi silang parsial. Dua kajian bobot lainnya yaitu bobot konektivitas dan segi tiga atas sebagai usulan kajian bobot. Model yang digunakan adalah *full model* dengan menyertakan seluruh parameter dan *restricted model* dengan hanya menyertakan parameter signifikan dalam model dengan taraf signifikan $\alpha = 0,01$.

4.4.2.1 Pemodelan GSTAR (1₁) dengan Bobot Invers Jarak

Pemodelan GSTAR-GLS (1₁) dengan bobot invers jarak menggunakan pendekatan jarak tempuh transportasi laut antar lokasi (D). Matriks jarak antar lokasi yang dibuat sebagai berikut:

$$D = \begin{bmatrix} 0 & 824 & 1207 \\ 824 & 0 & 390 \\ 1207 & 390 & 0 \end{bmatrix}.$$

Pemodelan GSTAR-GLS (1₁) dengan menggunakan bobot invers jarak mengasumsikan bahwa data inflasi bahan makanan suatu lokasi dipengaruhi oleh jarak lokasi tersebut dengan lokasi lainnya. Jarak antar lokasi yang lebih jauh cenderung memiliki bobot yang lebih rendah dibandingkan jarak antar lokasi yang lebih dekat. Berdasarkan hasil normalisasi jarak antar lokasi diperoleh bobot invers jarak tempuh transportasi laut (W) sebagai berikut :

$$W = \begin{bmatrix} 0 & 0,59 & 0,41 \\ 0,32 & 0 & 0,68 \\ 0,24 & 0,76 & 0 \end{bmatrix}.$$

a. Full Model

Hasil perhitungan estimasi parameter model GSTAR- GLS (1₁) bobot invers jarak dapat dilihat pada Tabel 4.31. Secara umum, seluruh parameter hasil estimasi masih ada yang tidak signifikan $\alpha= 10\%$. Terlihat dependensi wilayah hanya signifikan pada wilayah Manokwari pada tingkat signifikansi $\alpha= 5\%$. Hasil estimasi parameter pada Tabel 4.31 selanjutnya digunakan untuk menyusun persamaan matriks persamaan GSTAR antar wilayah untuk melihat pengaruh dependensi antar wilayah.

Tabel 4.31 Estimasi Parameter *Full Model* GSTAR-GLS (1₁) Bobot Invers Jarak pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,246	0,112	-2,2	0,0306
	ϕ_{11}^1	1	0,236	0,150	1,58	0,1190
Manokwari	ϕ_{10}^1	1	-0,040	0,108	-0,37	0,7159
	ϕ_{11}^1	1	0,401	0,158	2,54	0,0131
Sorong	ϕ_{10}^1	1	0,976	0,031	31,96	0,0001
	ϕ_{11}^1	1	-0,031	0,030	-1,03	0,3043

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,246 & 0 & 0 \\ 0 & -0,040 & 0 \\ 0 & 0 & 0,967 \end{bmatrix} + \begin{bmatrix} 0,236 & 0 & 0 \\ 0 & 0,401 & 0 \\ 0 & 0 & -0,031 \end{bmatrix} \begin{bmatrix} 0 & 0,59 & 0,41 \\ 0,32 & 0 & 0,68 \\ 0,24 & 0,76 & 0 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,246 & 0,140 & 0,096 \\ 0,129 & -0,040 & 0,272 \\ -0,008 & -0,023 & 0,976 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot invers jarak dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,246\dot{Y}_{1,t-1} + 0,140\dot{Y}_{2,t-1} + 0,096\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,129\dot{Y}_{1,t-1} - 0,040\dot{Y}_{2,t-1} + 0,272\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = -0,008\dot{Y}_{1,t-1} - 0,023\dot{Y}_{2,t-1} + 0,976\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

Hasil model untuk masing-masing lokasi menunjukkan bahwa inflasi bahan makanan suatu lokasi dipengaruhi oleh inflasi bahan makanan lokasi lain diwaktu yang berbeda. Hasil model GSTAR-GLS (1₁) menunjukkan bahwa kota dengan lokasi terdekat akan memberikan pengaruh yang besar terhadap perkembangan inflasi suatu wilayah. Misalnya inflasi bahan makanan Kota

Manokwari lebih dipengaruhi inflasi Kota Sorong dibandingkan Kota Jayapura, karena jarak lokasi yang dekat antar kedua kota tersebut.

b. Restricted Model

Estimasi parameter yang dihasilkan model GSTAR- GLS (1₁) tidak semuanya menghasilkan parameter yang signifikan. Oleh karena itu, pada pemodelan akhir akan dilakukan proses *restricted*, yaitu hanya memasukan parameter yang signifikan dalam model. Pemodelan parameter model GSTAR-GLS (1₁) bobot invers jarak dapat dilihat pada Tabel 4.32. Hasil persamaan menunjukkan parameter dependensi di Kota anokwari signifikan yang berarti terdapat pengaruh wilayah lain terhadap inflasi di kota tersebut.

Tabel 4.32 Estimasi Parameter *Restricted Model* GSTAR-GLS (1₁) Bobot Invers Jarak Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,195	0,110	-1,78	0,0789
Manokwari	ϕ_{11}^1	1	0,364	0,148	2,46	0,0162
Sorong	ϕ_{10}^1	1	0,962	0,029	32,94	0,0001

Hasil estimasi parameter pada Tabel 4.32 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot invers jarak sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,195 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,962 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0,364 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,59 & 0,41 \\ 0,32 & 0 & 0,68 \\ 0,24 & 0,76 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,195 & 0 & 0 \\ 0,117 & 0 & 0,247 \\ 0 & 0 & 0,958 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot invers jarak dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,195\dot{Y}_{1,t-1} + \varepsilon_{1,t}$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,117\dot{Y}_{2,t-1} + 0,247\dot{Y}_{3,t-1} + \varepsilon_{2,t}$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,962\dot{Y}_{3,t-1} + \varepsilon_{3,t}$$

Hasil estimasi parameter yang telah di-*restrict* menunjukkan bahwa semua parameter signifikan pada $\alpha = 5\%$. Model GSTAR-GLS (1₁) menunjukkan bahwa hanya wilayah Manokwari yang memiliki dependensi spasial dengan wilayah sekitarnya yaitu Kota Sorong dan Jayapura. Sedangkan inflasi bahan makanan di Kota Jayapura tidak memiliki model GSTAR -GLS (1₁). Hal ini sesuai dengan identifikasi awal bahwa mulai lag (0) pada plot MCCF Kota Manokwari cenderung memiliki ketergantungan spasial dengan wilayah Sorong pada waktu yang sama.

4.4.2.2 Bobot Normalisasi Korelasi Silang (NKS)

Pemodelan GSTAR-GLS (1₁) menggunakan bobot Normalisasi Korelasi Silang (NKS) mengasumsikan bahwa keterkaitan inflasi bahan makanan antar lokasi lebih dipengaruhi oleh tinggi rendahnya korelasi yang dimiliki inflasi bahan makanan suatu lokasi dengan lokasi yang lainnya. Penghitungan bobot NKS diperoleh melalui normalisasi dari nilai korelasi silang antar lokasi pada lag yang bersesuaian.

Berdasarkan plot MCCF dan nilai *Cross-Correlation* variabel dependent (inflasi bahan makanan) pada Lampiran 1 diperoleh nilai *cross*-korelasi antar variabel dependent. Sehingga berdasarkan nilai *cross*-korelasi tersebut diperoleh matriks bobot NKS yang digunakan untuk mengestimasi parameter model GSTAR-GLS (1₁) untuk lag 1 dapat dituliskan sebagai berikut :

$$W = \begin{bmatrix} 0 & 0,60 & -0,40 \\ 0,40 & 0 & 0,60 \\ -0,51 & 0,49 & 0 \end{bmatrix}$$

a. Full Model

Hasil perhitungan estimasi parameter model GSTAR-GLS (1₁) bobot normalisasi korelasi silang dapat dilihat pada Tabel 4.33. Hasil estimasi parameter pada Tabel 4.33 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot normalisasi korelasi silang.

Tabel 4.33 Estimasi Parameter *Full Model* GSTAR-GLS (1₁) Bobot NKS Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,180	0,112	-1,60	0,1132
	ϕ_{11}^1	1	0,060	0,189	0,32	0,7517
Manokwari	ϕ_{10}^1	1	-0,058	0,109	-0,53	0,5985
	ϕ_{11}^1	1	0,402	0,161	2,50	0,0144
Sorong	ϕ_{10}^1	1	0,966	0,029	33,07	<,0001
	ϕ_{11}^1	1	-0,058	0,039	-1,50	0,1375

Hasil estimasi pada Tabel 4.33 selanjutnya dapat digunakan untuk menyusun persamaan matriks model GSTAR-GLS(1₁) bobot normalisasi korelasi silang kedalam persamaan berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,180 & 0 & 0 \\ 0 & -0,058 & 0 \\ 0 & 0 & 0,966 \end{bmatrix} + \begin{bmatrix} 0,060 & 0 & 0 \\ 0 & 0,402 & 0 \\ 0 & 0 & -0,058 \end{bmatrix} \begin{bmatrix} 0 & 0,60 & -0,40 \\ 0,40 & 0 & 0,60 \\ -0,51 & 0,49 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,180 & 0,036 & -0,024 \\ 0,160 & -0,058 & 0,242 \\ 0,030 & -0,028 & 0,966 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot normalisasi korelasi silang dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,180\dot{Y}_{1,t-1} + 0,036\dot{Y}_{2,t-1} - 0,024\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,160\dot{Y}_{1,t-1} - 0,058\dot{Y}_{2,t-1} + 0,242\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,030\dot{Y}_{1,t-1} - 0,028\dot{Y}_{2,t-1} + 0,966\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

b. *Restricted Model*

Hasil perhitungan estimasi parameter model GSTAR- GLS (1₁) bobot normalisasi korelasi silang dapat dilihat pada Tabel 4.34. Terlihat bahwa penggunaan bobot spasial normalisasi korelasi silang model GSTAR menunjukkan bahwa terdapat pengaruh dependensi antar wilayah pada inflasi di Kota Manokwari. Hasil estimasi parameter pada Tabel 4.34 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot normalisasi korelasi silang.

Tabel 4.34 Estimasi Parameter *Restricted Model* GSTAR-GLS (1₁) Bobot Normalisasi Korelasi Silang Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,191	0,110	-1,74	0,0863
Manokwari	ϕ_{11}^1	1	0,362	0,149	2,43	0,0174
Sorong	ϕ_{10}^1	1	0,962	0,029	32,94	<,0001

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,191 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,962 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0,362 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,60 & -0,40 \\ 0,40 & 0 & 0,60 \\ -0,51 & 0,49 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,191 & 0 & 0 \\ 0,145 & 0 & 0,218 \\ 0 & 0 & 0,962 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot normalisasi korelasi silang dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,191\dot{Y}_{1,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,145\dot{Y}_{1,t-1} + 0,218\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,962\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

Pada taraf signifikansi $\alpha = 0,1$ hasil estimasi parameter model menunjukkan bahwa inflasi bahan makanan pada Kota Manokwari memiliki parameter spasial atau keterkaitan spasial dengan Kota Jayapura dan Sorong satu waktu sebelumnya. Sedangkan inflasi bahan makanan di Kota Sorong dan Jayapura tidak dipengaruhi oleh wilayah lain.

4.4.2.3 Bobot Normalisasi Inferensia Parsial Korelasi Silang (NIPKS)

Pemodelan GSTAR-GLS (1₁) menggunakan bobot Normalisasi Inferensia Parsial Korelasi Silang (NIPKS) mengasumsikan bahwa keterkaitan inflasi bahan makanan antar lokasi dipengaruhi oleh hasil inferensia parsial korelasi silang pada data inflasi bahan makanan suatu lokasi tersebut. Penghitungan bobot NIPKS diperoleh melalui normalisasi dari nilai korelasi silang antar lokasi pada lag yang bersesuaian. Nilai korelasi silang tersebut dapat diperoleh dari nilai matriks *cross-korelasi* parsial antar variabel dependen. Pemberian bobot juga didasarkan pada simbol skema plot MPCCF dimana selain simbol titik (.) maka bobot inferensia korelasi silang antar wilayah tersebut di lag yang bersesuaian memiliki nilai (Lampiran 2).

Matriks bobot NIPKS yang digunakan untuk mengestimasi parameter model GSTAR-GLS (1₁) untuk lag 1 dapat dituliskan sebagai berikut :

$$W = \begin{bmatrix} 0 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 0 \end{bmatrix}.$$

a. Full Model

Hasil perhitungan estimasi parameter model GSTAR-GLS (1₁) bobot NIPKS dapat dilihat pada Tabel 4.35. Hasil estimasi parameter pada Tabel 4.35 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot normalisasi inferensia korelasi silang parsial sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,232 & 0 & 0 \\ 0 & 0,048 & 0 \\ 0 & 0 & 0,958 \end{bmatrix} + \begin{bmatrix} -0,156 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & -0,007 \end{bmatrix} \begin{bmatrix} 0 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,232 & 0 & 0,156 \\ 0 & 0,048 & 0 \\ 0,007 & 0 & 0,958 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Tabel 4.35 Estimasi Parameter *Full Model* GSTAR-GLS (1₁) Bobot NIPKS Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,232	0,111	-2,1	0,0392
	ϕ_{11}^1	1	-0,156	0,135	-1,16	0,2507
Manokwari	ϕ_{10}^1	1	0,048	0,105	0,46	0,645
Sorong	ϕ_{10}^1	1	0,958	0,030	32,22	<,0001
	ϕ_{11}^1	1	-0,007	0,024	-0,28	0,7791

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot normalisasi inferensia korelasi silang parsial dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,203\dot{Y}_{1,t-1} + 0,156\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,048\dot{Y}_{2,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,007\dot{Y}_{1,t-1} + 0,958\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

b. Restricted Model

Estimasi parameter yang dihasilkan pada *full model* tidak sepenuhnya signifikan pada $\alpha = 0,1$ sehingga perlu dilakukan estimasi ulang dengan mengeluarkan variabel yang tidak signifikan. Hasil perhitungan estimasi parameter model GSTAR-GLS (1₁) bobot normalisasi inferensia korelasi silang parsial dapat dilihat pada Tabel 4.36. Hasil estimasi parameter pada Tabel 4.36 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot normalisasi inferensia korelasi silang parsial sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,296 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,261 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Tabel 4.36 Estimasi Parameter *Restricted Model* GSTAR-GLS (1₁) Bobot Normalisasi Inferensia Parsial Korelasi Silang pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,296	0,109	-2,73	0,0078
Sorong	ϕ_{10}^1	1	-0,261	0,125	-2,08	0,0404

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot normalisasi inferensia korelasi silang parsial dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,296\dot{Y}_{1,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = -0,261\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

Berdasarkan *restricted model* GSTAR-GLS (1₁), Kota Jayapura dan Manokwari tidak memiliki model GSTAR-GLS (1₁). Berdasarkan tingkat signifikansi $\alpha = 0,05$, hanya Kota Sorong memiliki model GSTAR-GLS (1₁) dimana inflasi bahan makanan di Kota Sorong dipengaruhi oleh inflasi bulan sebelumnya.

4.4.2.4 Bobot Konektivitas

Model *Gravity* dalam spasial ekonometrik telah mempertimbangkan konektivitas transportasi antar wilayah sehingga pemberian bobot spasial dalam model merupakan cara yang sederhana dalam mendefinisikan ketergantungan spasial antar wilayah. Bobot tersebut menitik beratkan lag spasial wilayah penghasil “*origin*” ke wilayah tujuan “*destination*”. Oleh sebab itu, berdasarkan konsep tersebut dibuatlah suatu matriks bobot yang merepresentasikan arus barang dari wilayah penghasil ke wilayah tujuan melalui matriks konektivitas.

Bobot konektivitas dalam pemodelan GSTAR mengasumsikan bahwa data inflasi bahan makanan memiliki keterkaitan spasial (lokasi) yang dipengaruhi

oleh konektifitas moda transportasi antar wilayahnya (w_{ij}) dengan ($i \neq j$).

Matriks konektifitas antar wilayah dibuat sebagai berikut :

$$W = \begin{bmatrix} 0 & 6 & 8 \\ 6 & 0 & 8 \\ 8 & 8 & 0 \end{bmatrix}.$$

Berdasarkan hasil normalisasi bobot konektifitas diperoleh matrik bobot konektifitas sebagai berikut :

$$W' = \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix}.$$

a. *Full Model*

Perhitungan estimasi paramater dapat menggunakan matriks konektivitas tersebut. Hasil perhitungan estimasi parameter pada model GSTAR-GLS (1_1) bobot konektifitas untuk pemodelan data inflasi bahan makanan di Pulau Papua dapat ditunjukkan pada Tabel 4.37. Hasil estimasi tersebut akan dirangkum pada penulisan persamaan matriks model.

Tabel 4.37 Estimasi Parameter *Full Model* GSTAR-GLS (1_1) Bobot Konektivitas pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,238	0,112	-2,13	0,0365
	ϕ_{11}^1	1	0,265	0,156	1,69	0,0943
Manokwari	ϕ_{10}^1	1	-0,034	0,108	-0,32	0,7524
	ϕ_{11}^1	1	0,398	0,160	2,49	0,0147
Sorong	ϕ_{10}^1	1	0,971	0,031	31,8	0,0001
	ϕ_{11}^1	1	-0,017	0,032	-0,51	0,608

Hasil estimasi parameter pada Tabel 4.37 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1_1) bobot konektivitas sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,238 & 0 & 0 \\ 0 & -0,034 & 0 \\ 0 & 0 & 0,971 \end{bmatrix} + \begin{bmatrix} 0,265 & 0 & 0 \\ 0 & 0,398 & 0 \\ 0 & 0 & -0,017 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,238 & 0,113 & 0,151 \\ 0,180 & -0,034 & 0,228 \\ -0,008 & -0,008 & 0,971 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot konektivitas dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura
 $\dot{Y}_{1,t} = -0,238\dot{Y}_{1,t-1} + 0,113\dot{Y}_{2,t-1} + 0,151\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$
- Model GSTAR-GLS (1₁) di Kota Manokwari
 $\dot{Y}_{2,t} = 0,171\dot{Y}_{1,t-1} - 0,034\dot{Y}_{2,t-1} + 0,228\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$
- Model GSTAR-GLS (1₁) di Kota Sorong
 $\dot{Y}_{3,t} = -0,008\dot{Y}_{1,t-1} - 0,008\dot{Y}_{2,t-1} + 0,971\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$

b. Restricted Model

Hasil pemodelan GSTAR- GLS (1₁) bobot normalisasi inferensia korelasi silang parsial dapat dilihat pada Tabel 4.38.

Tabel 4.38 Estimasi Parameter *Restricted Model* GSTAR-GLS (1₁) Bobot Konektivitas pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,232	0,111	-2,09	0,0396
	ϕ_{11}^1	1	0,274	0,155	1,76	0,0818
Manokwari	ϕ_{11}^1	1	0,387	0,150	2,58	0,0116
Sorong	ϕ_{10}^1	1	0,967	0,029	32,96	<,0001

Hasil estimasi parameter pada Tabel 4.38 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1₁) bobot normalisasi inferensia korelasi silang parsial sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,232 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,967 \end{bmatrix} + \begin{bmatrix} 0,274 & 0 & 0 \\ 0 & 0,387 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,232 & 0,117 & 0,156 \\ 0,166 & 0 & 0,221 \\ 0 & 0 & 0,967 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot konektivitas dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,232\dot{Y}_{1,t-1} + 0,117\dot{Y}_{2,t-1} + 0,156\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,166\dot{Y}_{1,t-1} + 0,221\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,967\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

Output *restriced model* GSTAR-GLS (1₁) menunjukkan kesimpulan yang serupa dengan bobot sebelumnya bahwa inflasi bahan makanan di Kota Manokwari yang memiliki keterkaitan spasial dengan wilayah sekitarnya. Pengaruh spasial Kota Sorong terhadap Kota Manokwari lebih besar dibandingkan kota Jayapura. Keterkaitan tersebut merupakan refleksi kedekatan wilayah Manokwari terhadap Kota Sorong yang lebih sering berinteraksi sebagai wilayah administratif dalam satu provinsi.

4.4.2.5 Bobot Matriks Segi Tiga Atas

Bobot matriks segi tiga atas masih menitikberatkan ketergantungan antar daerah sebagai bentuk interaksi antar wilayah yang direpresentasikan sebagai kemudahan akses transportasi. Namun yang berbeda dengan bobot sebelumnya adalah arah arus interaksi turut menjadi perhatian. Dengan tetap memegang konsep model ekonometrika bahwa arus barang selalu berasal dari daerah penghasil maka terdapat peluang bersyarat dari isi setiap sel matriks pembobot. Berdasarkan latar belakang yang telah dibahas sebelumnya bahwa arus komoditas bahan makanan berasal dari luar pulau dan hanya didistribusikan melalui kapal laut dengan arah kapal dari Sorong menuju Manokwari dan berakhir di Jayapura. Maka dapat diasumsikan bahwa Kota Sorong tidak memiliki ketergantungan spasial dengan dua wilayah lainnya sedangkan Kota Manokwari tidak memiliki ketergantungan spasial dengan Kota Jayapura.

Bobot matriks segi tiga atas dalam pemodelan GSTAR tetap menggunakan keterkaitan spasial (lokasi) yang dipengaruhi oleh konektivitas moda

transportasi antar wilayahnya (w_{ij}) dengan ($i \neq j$). Matriks konektifitas antar wilayah dibuat sebagai berikut :

$$W = \begin{bmatrix} 0 & 6 & 8 \\ 6 & 0 & 8 \\ 8 & 8 & 0 \end{bmatrix}.$$

Namun, pengaplikasiannya dalam bentuk matriks bobot dengan menambahkan peluang bersyarat dalam arus distribusi barang yang hanya satu arah. Prosedur estimasi parameter GSTAR- GLS (1_1) dengan bobot segi tiga atas sama halnya dalam proseduer estimasi VAR *restricted*, yaitu menjustifikasi nilai nol pada estimasi parameter tertentu. Akan tetapi, justifikasi yang dilakukan dalam adalah memberi nilai nol pada bobot wilayah yang tidak memiliki dependensi dengan wilayah tertentu. Sehingga diperoleh matrik bobot segi tiga atas sebagai berikut :

$$W' = \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix}.$$

a. Full Model

Hasil perhitungan estimasi parameter model GSTAR-GLS (1_1) bobot matriks segi tiga atas dapat dilihat pada Tabel 4.39.

Tabel 4.39 Estimasi Parameter *Full Model* GSTAR-GLS (1_1) Bobot Matriks Segi Tiga Atas Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,263	0,111	-2,38	0,0198
	ϕ_{11}^1	1	0,287	0,157	1,83	0,071
Manokwari	ϕ_{10}^1	1	-0,005	0,106	-0,05	0,9606
	ϕ_{11}^1	1	0,526	0,228	2,3	0,0239
Sorong	ϕ_{10}^1	1	0,969	0,029	32,89	0,0001

Hasil estimasi parameter pada Tabel 4.39 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1_1) bobot matriks segi tiga atas sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,263 & 0 & 0 \\ 0 & -0,005 & 0 \\ 0 & 0 & 0,969 \end{bmatrix} + \begin{bmatrix} 0,287 & 0 & 0 \\ 0 & 0,526 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,263 & 0,123 & 0,164 \\ 0 & -0,005 & 0,300 \\ 0 & 0 & 0,969 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1_1) untuk data inflasi bahan makanan dengan bobot matriks segi tiga atas dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1_1) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,265\dot{Y}_{1,t-1} + 0,123\dot{Y}_{2,t-1} + 0,164\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1_1) di Kota Manokwari

$$\dot{Y}_{2,t} = -0,005\dot{Y}_{2,t-1} + 0,300\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1_1) di Kota Sorong

$$\dot{Y}_{3,t} = 0,969\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

b. Restricted Model

Pemilihan parameter yang signifikan dapat menggunakan model *restricted*. Hasil perhitungan estimasi parameter model *restricted* GSTAR- GLS (1_1) bobot matriks segi tiga atas dapat dilihat pada Tabel 4.40. Pengaruh dependensi antar wilayah hanya terdapat pada persamaan GSTAR wilayah Jayapura.

Tabel 4.40 Estimasi Parameter *Restricted Model* GSTAR-GLS (1_1) Matriks Segi Tiga Atas Pada Tiga Kota di Pulau Papua

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,263	0,111	-2,38	0,0197
	ϕ_{11}^1	1	0,288	0,156	1,84	0,0692
Manokwari	ϕ_{11}^1	1	0,523	0,219	2,390	0,0191
Sorong	ϕ_{10}^1	1	0,969	0,029	32,89	<,0001

Hasil estimasi parameter pada Tabel 4.40 selanjutnya digunakan untuk menyusun persamaan matriks model GSTAR-GLS (1_1) bobot matriks segi tiga atas sebagai berikut:

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,263 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0,969 \end{bmatrix} + \begin{bmatrix} 0,288 & 0 & 0 \\ 0 & 0,523 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix} \right) \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} \dot{Y}_{1,t} \\ \dot{Y}_{2,t} \\ \dot{Y}_{3,t} \end{bmatrix} = \begin{bmatrix} -0,263 & 0,123 & 0,165 \\ 0 & 0 & 0,299 \\ 0 & 0 & 0,969 \end{bmatrix} \begin{bmatrix} \dot{Y}_{1,t-1} \\ \dot{Y}_{2,t-1} \\ \dot{Y}_{3,t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTAR-GLS (1₁) untuk data inflasi bahan makanan dengan bobot matriks segi tiga atas dapat dituliskan pada persamaan untuk setiap lokasi sebagai berikut:

- Model GSTAR-GLS (1₁) di Kota Jayapura

$$\dot{Y}_{1,t} = -0,263\dot{Y}_{1,t-1} + 0,123\dot{Y}_{2,t-1} + 0,165\dot{Y}_{3,t-1} + \varepsilon_{1,t}.$$

- Model GSTAR-GLS (1₁) di Kota Manokwari

$$\dot{Y}_{2,t} = 0,299\dot{Y}_{3,t-1} + \varepsilon_{2,t}.$$

- Model GSTAR-GLS (1₁) di Kota Sorong

$$\dot{Y}_{3,t} = 0,969\dot{Y}_{3,t-1} + \varepsilon_{3,t}.$$

Dengan memberikan peluang bersyarat pada matriks bobot untuk wilayah sorong maka inflasi bahan makanan, maka hanya Kota Jayapura yang memiliki ketergantungan spasial dengan Kota Sorong dan Manokwari. Sedangkan dua kota lainnya hanya dipengaruhi inflasi pada wilayahnya sendiri satu waktu sebelumnya. Pengaruh tersebut bernilai positif dengan pengaruh wilayah Sorong lebih tinggi dibanding Manokwari.

4.4.3. Diagnostic Checking Model GSTAR-GLS (1₁)

Prosedur selanjutnya adalah pengujian asumsi residual yang *white noise* pada residual model sehingga model tersebut dianggap layak untuk digunakan dalam peramalan. Pengujian dilakukan dengan cara memodelkan ulang residual dari model GSTAR-GLS (1₁) dan mengecek letak nilai AIC terkecil.

Berdasarkan Tabel 4.41 dapat diketahui nilai AIC terkecil pada *full* model GSTAR-GLS untuk kelima bobot berada pada lag AR(0) dan MA(0). Nilai AIC terkecil terdapat pada bobot konektivitas sebesar 2,973, disusul oleh bobot normalisasi korelasi silang sebesar 2,983 dan selanjutnya bobot invers jarak 2,988. Hal ini berarti bahwa asumsi residual *white noise* secara keseluruhan telah terpenuhi dan setiap model dari masing-masing bobot dapat digunakan untuk peramalan.

Tabel 4.41 Nilai AIC Residual Model GSTAR-GLS (1_1) (*Full Model*) Berdasarkan Bobot Lokasi Pada Data IBM Tiga Kota di Pulau Papua

Bobot Lokasi	Lag	MA(0)	MA(1)	MA(2)
Invers Jarak	AR(0)	2,955	3,167	3,067
	AR(1)	3,106	3,310	3,250
Normalisasi Korelasi Silang	AR(0)	2,983	3,235	3,060
	AR(1)	3,121	3,327	3,218
Normalisasi Inferensia Korelasi Silang	AR(0)	3,046	3,329	3,215
	AR(1)	3,134	3,425	3,352
Konektivitas	AR(0)	2,973	3,167	3,085
	AR(1)	3,087	3,312	3,270
Segi Tiga Atas	AR(0)	3,006	3,239	3,131
	AR(1)	3,113	3,332	3,276

Perhitungan nilai AIC juga dilakukan pada model GSTAR-GLS (1_1) *restricted*, seperti yang terlihat pada Lampiran 5. Hal serupa terjadi pada model GSTAR-GLS (1_1) *restricted* dimana setiap bobot telah menunjukkan nilai kriteria minimum terdapat pada lag AR(0) dan MA(0), kecuali untuk bobot normalisasi inferensia parsial korelasi silang yang tidak tepat berada pada lag AR(0) dan MA(0). Kesimpulan yang sama diberikan bahwa asumsi residual *white noise* terhadap residual telah terpenuhi kecuali untuk bobot normalisasi inferensia parsial korelasi silang.

4.4.4. Pemilihan Model Terbaik Model GSTAR-GLS (1_1)

Setelah mendapatkan model yang layak digunakan dalam peramalan selanjutnya dilakukan pemilihan model terbaik menggunakan nilai RMSE *out-sample* terkecil. Berdasarkan Tabel 4.42 peramalan *full* model GSTAR-GLS (1_1) dengan bobot matriks segi tiga atas memberikan nilai RMSE terkecil sebesar 2,185.

Namun secara parsial per wilayah, pemilihan model GSTAR-GLS (1_1) terbaik memberikan kesimpulan penggunaan bobot yang berbeda. *Full* model GSTAR-GLS (1_1) dengan bobot normalisasi korelasi silang lebih baik dalam

meramalkan inflasi bahan makanan di Kota Manokwari dan Jayapura. Penggunaan bobot matriks segi tiga atas pada *full* model GSTAR-GLS (1₁) baik dalam meramalkan inflasi bahan makanan di Kota Sorong.

Tabel 4.42 Nilai RMSE *Out-Sample* menurut bobot lokasi pada Pemodelan GSTAR-GLS (1₁)

Model	Bobot Lokasi	Jayapura	Manokwari	Sorong	Rata-rata RMSE
<i>Full Model</i>	Invers Jarak	1,268	3,195	2,347	2,270
	NKS	1,268	3,195	2,347	2,270
	NIPKS	1,259	3,167	2,446	2,291
	Konektivitas	1,272	3,191	2,214	2,226
	Segi Tiga Atas	1,288	3,208	2,059	2,185
<i>Restricted Model</i>	Invers Jarak	1,271	3,187	2,381	2,280
	NKS	1,271	3,187	2,29	2,249
	Konektivitas	1,263	3,196	2,348	2,269
	Segi Tiga Atas	1,288	3,208	2,364	2,287

Peramalan inflasi di wilayah Jayapura dan Manokwari memiliki ketergantungan spasial dengan wilayah sekitarnya satu waktu sebelumnya tanpa melibatkan faktor eksogen. Ketergantungan tersebut sudah tidak melibatkan faktor jarak namun lebih kepada tinggi rendahnya korelasi inflasi antar wilayah. Penggunaan bobot matriks segi tiga atas menunjukkan bahwa inflasi bahan makanan di Kota Sorong tidak memiliki keterkaitan dengan wilayah lain satu waktu sebelumnya.

4.5 Pemodelan GSTARX untuk Peramalan Inflasi Bahan Makanan di Pulau Papua dengan Variabel Eksogen Data Metrik

Secara umum dalam pemodelan GSTARX dengan menggunakan variabel eksogen data metrik meliputi dua tahapan yaitu pemodelan fungsi transfer, pemodelan GSTAR-GLS. Dan pemodelan GSTARX dengan melakukan kombinasi hasil ramalan model fungsi transfer multi input dan hasil ramalan pemodelan GSTAR-GLS. Berikut hasil analisis dan pembahasan setiap tahapannya.

4.5.1. Pemodelan Tahapan Pertama dengan Model Fungsi Transfer

Model fungsi transfer pada tahap pertama dilakukan untuk mendapatkan hasil ramalan pertama dan residual ($n_{i,t}$) yang akan digunakan untuk analisis lebih lanjut. Pemodelan fungsi transfer multi input dilakukan dengan menggunakan input deret data yang signifikan pada tahapan pemodelan fungsi transfer sebelumnya.

Tahapan identifikasi untuk pemodelan ARIMA pada deret input seperti yang telah dijelaskan sebelumnya. Berdasarkan hasil CCF antara deret output inflasi dengan deret input tinggi gelombang dan kecepatan angin diperoleh model fungsi transfer untuk masing-masing lokasi. Setelah mendapatkan fungsi transfer selanjutnya dilakukan estimasi parameter dari model fungsi transfer untuk tiap lokasi. Estimasi parameter model fungsi transfer pada tahapan ini dilakukan tanpa melakukan pemodelan ARIMA untuk residual. Selain itu asumsi *white noise* juga diabaikan ($n_{i,t}$) dikarenakan pengujian asumsi akan dilakukan pada tahap selanjutnya, terkecuali residual model fungsi transfer yang telah memenuhi asumsi *white noise*. Secara matematis model fungsi transfer yang diperoleh sebagai berikut:

- a. Kota Jayapura

$$y_{1,t} = 3,324 - 2,215x_{21,t-2} + n_{1,t}$$

- b. Kota Manokwari

$$y_{2,t} = 0,566x_{22,t-6} + n_{2,t}$$

- c. Kota Sorong


$$y_{3,t} = 2,696 + 0,364x_{23,t} + 0,451x_{23,t-2} + n_{3,t}$$

Model yang diperoleh digunakan untuk mendapatkan hasil peramalan tahap pertama $\hat{y}_{i,t}$ dan residual ($n_{i,t}$). Pada tahapan selanjutnya residual ($n_{i,t}$) dengan $i = 1,2,3$ untuk masing-masing lokasi menjadi variabel respon pada tahap 2 (dua).

4.5.2. Identifikasi Model GSTARX

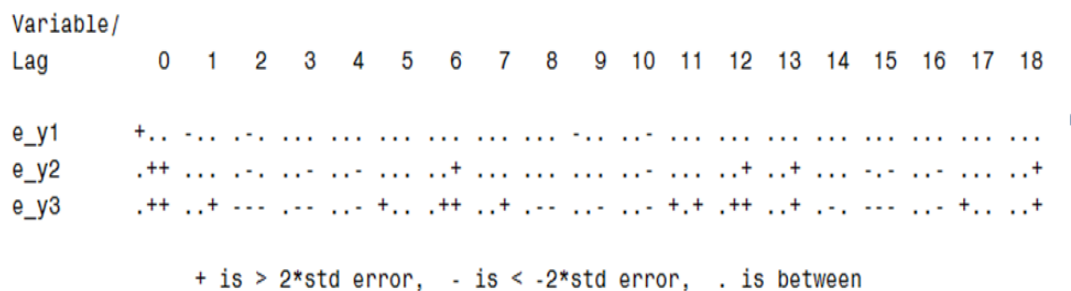
Hasil residual pada tahap pertama selanjutnya digunakan sebagai variabel respon untuk pemodelan GSTAR. Prosedur awal dalam pemodelan GSTAR

adalah identifikasi residual ($n_{i,t}$) untuk masing-masing lokasi. Identifikasi stasioneritas residual dapat menggunakan plot time series residual dan plot MCCF. Hasil plot residual dapat dilihat pada Gambar 4.29.



Gambar 4.29 Plot time series residual ($n_{i,t}$) Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua

Berdasarkan plot *time series* data residual inflasi bahan makanan tiga lokasi secara visual menunjukkan bahwa data sudah stasioner karena bergerak dengan pola yang tetap pada rata-rata. Tahapan identifikasi selanjutnya dilakukan untuk mengetahui stasioner data dengan menggunakan plot MCCF seperti yang ditunjukkan pada Gambar 4.30. Skema MCCF pada Gambar 4.30 menunjukkan bahwa data residual di tiga lokasi telah stasioner. Hal ini terlihat dari banyaknya tanda titik (.) yang muncul dalam plot MCCF tersebut.

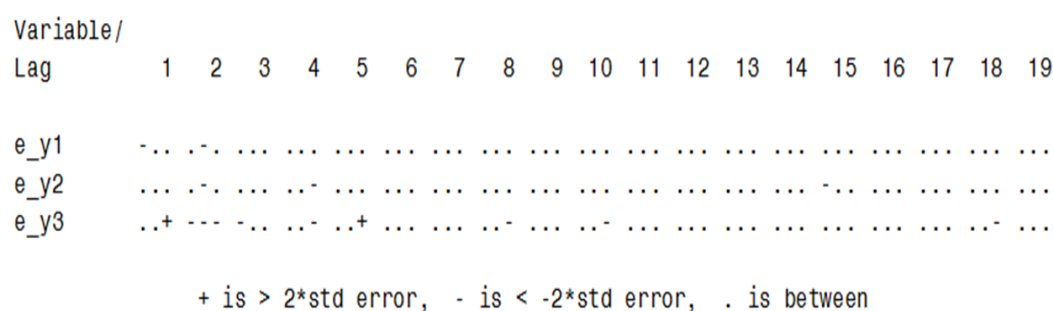


Gambar 4.30 Representasi Skema MCCF untuk ($n_{i,t}$) Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua

Demikian halnya dengan interpretasi tanda positif pada skema MCCF lag 0, residual estimasi tahap pertama menunjukkan masih adanya pengaruh dependensi

antar wilayah selain faktor cuaca di waktu yang sama. Namun dependensi yang terjadi hanya pada Kota Sorong dan Manokwari. Pengaruh faktor cuaca mampu menjelaskan ketersediaan komoditas ikan segar sedangkan ketersediaan komoditas pangan lainnya dapat dijelaskan oleh faktor dependensi kedua wilayah tersebut.

Penentuan orde waktu (AR) dengan pemodelan GSTAR memiliki proses yang sama dengan pemodelan VAR yaitu dilakukan dengan menggunakan nilai *Corrected Akaike's Information Criterion* (AICC) terkecil dan plot MPCCF dari data yang sudah stasioner. Hasil skema MPCCF memetakan nilai korelasi silang parsial dari lag yang berada diluar nilai standar deviasi yang ditunjukkan oleh tanda (+) dan (-). Banyaknya tanda (+) dan (-) pada lag tertentu diduga sebagai lag yang sesuai untuk model GSTAR.



Gambar 4.31 Representasi Skema MPCCF untuk $(n_{i,t})$ Inflasi Bahan Makanan Tiga Lokasi di Pulau Papua

Skema MPCCF pada Gambar 4.31 menunjukkan bahwa tanda positif (+) dan negatif (-) banyak muncul pada lokasi di lag 1 dan 2. Untuk lebih meyakinkan, perbandingan nilai AICC terkecil dapat dilakukan pada orde model VAR antara lag 1 dan lag [1,2].

Tabel 4.43 Nilai AICC pada Dugaan Model VAR

Model	AICC
(1,0,0)	4,482
([1,2],0,0)	4,115

Dengan menggunakan perbandingan nilai AICC terkecil pada lag yang signifikan maka model yang terbentuk adalah VAR ([1,2]). Orde model selanjutnya digunakan dalam model GSTARX adalah lag 1 dan 2, sedangkan orde

spasial yang digunakan dibatasi pada orde spasial 1. Sehingga model GSTAR yang digunakan dalam penelitian ini adalah model GSTAR $([1,2]_1)$. Model GSTARX $([1,2]_1)$ dapat ditulis dengan persamaan sebagai berikut:

$$n_{i,t} = [\Phi_{10}^1 + \Phi_{11}W^1]n_{i,t-1} + [\Phi_{10}^1 + \Phi_{11}W^1]n_{i,t-2} + \varepsilon_{i,t}.$$

Sehingga dalam bentuk matriks persamaan tersebut diatas dapat ditulis sebagai berikut :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \left(\begin{bmatrix} \phi_{10}^1 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 \\ 0 & 0 & \phi_{30}^1 \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 \\ 0 & 0 & \phi_{31}^1 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{22} \\ w_{31} & w_{32} & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\ + \left(\begin{bmatrix} \phi_{10}^1 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 \\ 0 & 0 & \phi_{30}^1 \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 \\ 0 & 0 & \phi_{31}^1 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{22} \\ w_{31} & w_{32} & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

4.5.3. Estimasi Parameter pada Model GSTARX

Dalam pemodelan GSTARX residual $(n_{i,t})$ inflasi bahan makanan, metode estimasi parameter yang digunakan adalah estimasi GLS karena dapat menghasilkan varian estimasi yang lebih kecil. Oleh karena itu pemodelan GSTARX $([1,2]_1)$ pada data residual $(n_{i,t})$ inflasi bahan makanan di Pulau Papua selanjutnya disebut dengan pemodelan GSTAR-GLS $([1,2]_1)$.

Bobot lokasi yang digunakan dalam pemodelan GSTAR-GLS $([1,2]_1)$ untuk peramalan inflasi bahan makanan tiga lokasi di Pulau Papua yaitu bobot invers jarak, normalisasi korelasi silang, normalisasi inferensia parsial korelasi silang, konektivitas dan matriks segi tiga atas.

4.5.3.1 Pemodelan GSTARX-GLS $([1,2]_1)$ dengan Bobot Invers Jarak

a. Full Model

Perhitungan estimasi parameter model GSTARX-GLS $([1,2]_1)$ menggunakan bobot invers jarak dapat dilihat pada Tabel 4.44. Estimasi parameter pada Tabel 4.44 selanjutnya dapat digunakan untuk mebuat persamaan matriks model GSTARX-GLS $([1,2]_1)$ menggunakan bobot invers jarak yaitu :

Tabel 4.44 Estimasi Parameter *Full Model* GSTARX-GLS ([1,2]₁) dengan Bobot Invers Jarak Pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,349	0,123	-2,84	0,0059
	ϕ_{11}^1	1	-0,034	0,175	-0,2	0,8449
	ϕ_{10}^2	1	0,017	0,123	0,14	0,8892
	ϕ_{11}^2	1	0,027	0,151	0,18	0,8573
Manokwari	ϕ_{10}^1	1	-0,190	0,116	-1,64	0,1055
	ϕ_{11}^1	1	0,241	0,180	1,34	0,1843
	ϕ_{10}^2	1	-0,252	0,111	-2,28	0,0255
	ϕ_{11}^2	1	-0,008	0,173	-0,05	0,9616
Sorong	ϕ_{10}^1	1	0,168	0,117	1,44	0,1546
	ϕ_{11}^1	1	-0,108	0,113	-0,95	0,3432
	ϕ_{10}^2	1	-0,207	0,108	-1,92	0,0594
	ϕ_{11}^2	1	0,045	0,109	0,41	0,6833

$$\begin{aligned}
 \begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} &= \begin{bmatrix} -0,349 & 0 & 0 \\ 0 & -0,190 & 0 \\ 0 & 0 & 0,168 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\
 &+ \begin{bmatrix} -0,034 & 0 & 0 \\ 0 & 0,241 & 0 \\ 0 & 0 & -0,108 \end{bmatrix} \begin{bmatrix} 0 & 0,59 & 0,41 \\ 0,32 & 0 & 0,68 \\ 0,24 & 0,76 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\
 &+ \begin{bmatrix} 0,017 & 0 & 0 \\ 0 & -0,252 & 0 \\ 0 & 0 & -0,207 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} \\
 &+ \begin{bmatrix} 0,027 & 0 & 0 \\ 0 & -0,008 & 0 \\ 0 & 0 & 0,045 \end{bmatrix} \begin{bmatrix} 0 & 0,59 & 0,41 \\ 0,32 & 0 & 0,68 \\ 0,24 & 0,76 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}
 \end{aligned}$$

atau

$$\begin{aligned}
 \begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} &= \left(\begin{bmatrix} -0,349 & -0,020 & -0,014 \\ 0,077 & -0,190 & 0,164 \\ -0,026 & -0,081 & 0,168 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \left(\begin{bmatrix} 0,017 & 0,016 & 0,011 \\ -0,003 & -0,252 & -0,006 \\ 0,011 & 0,034 & -0,207 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} \\
 &+ \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.
 \end{aligned}$$

Model GSTARX-GLS ([1,2]₁) untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) Kota Jayapura
$$n_{1,t} = -0,349n_{1,t-1} - 0,020n_{2,t-1} - 0,014n_{3,t-1} + 0,017n_{1,t-2} + 0,016n_{2,t-2} + 0,011n_{3,t-2} + \varepsilon_{1,t} .$$
- Model GSTARX-GLS ([1,2]₁) Kota Manokwari
$$n_{2,t} = 0,077n_{1,t-1} - 0,190n_{2,t-1} + 0,164n_{3,t-1} - 0,003n_{1,t-2} - 0,252n_{2,t-2} - 0,006n_{3,t-2} + \varepsilon_{2,t} .$$
- Model GSTARX-GLS ([1,2]₁) Kota Sorong
$$n_{3,t} = -0,026n_{1,t-1} - 0,081n_{2,t-1} + 0,168n_{3,t-1} + 0,011n_{1,t-2} + 0,024n_{2,t-2} - 0,207n_{3,t-2} + \varepsilon_{3,t} .$$

b. *Restricted Model*

Estimasi parameter pada Tabel 4.44 tidak seluruhnya signifikan pada $\alpha = 0,1$ sehingga dilakukan pemodelan ulang GSTARX-GLS ([1,2]₁) dengan mengeluarkan parameter yang tidak signifikan. Hasil perhitungan dengan estimasi parameter model GSTARX-GLS ([1,2]₁) yang *restricted* dapat dilihat pada Tabel 4.45. Secara umum hasil estimasi menunjukkan tidak terdapat pengaruh spasial antar wilayah. Inflasi pada masing-masing wilayah hanya dipengaruhi oleh inflasi wilayah tersebut satu dan dua waktu sebelumnya.

Tabel 4.45 Estimasi Parameter *Restricted Model* GSTARX-GLS ([1,2]₁) dengan Bobot Invers Jarak Pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,374	0,113	-3,32	0,0014
Manokwari	ϕ_{10}^2	1	-0,245	0,098	-2,5	0,0145
Sorong	ϕ_{10}^2	1	-0,165	0,098	-1,67	0,0986

Estimasi parameter pada Tabel 4.45 selanjutnya dapat digunakan untuk membentuk persamaan matriks model GSTARX-GLS ([1,2]₁) *restricted* menggunakan bobot invers jarak yaitu :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,374 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,245 & 0 \\ 0 & 0 & -0,165 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix} .$$

Model GSTAR-GLS ([1,2]₁) *restricted* untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) Kota Jayapura

$$n_{1,t} = -0,374n_{1,t-1} + \varepsilon_{1,t} .$$

- Model GSTARX-GLS ([1,2]₁) Kota Manokwari

$$n_{2,t} = -0,245n_{1,t-2} + \varepsilon_{2,t} .$$

- Model GSTARX-GLS ([1,2]₁) Kota Sorong

$$n_{3,t} = -0,165n_{3,t-2} + \varepsilon_{3,t} .$$

Berdasarkan model yang terbentuk, inflasi bahan makanan di Pulau Papua tidak saling mempengaruhi. Hal ini berarti dengan mengesampingkan faktor jarak dan lebih mempertimbangkan korelasi inflasi antar wilayah, maka inflasi di Pulau Papua yang sudah memasukkan unsur faktor eksogen sudah tidak saling mempengaruhi .

4.5.3.2 Pemodelan GSTARX-GLS ([1,2]₁) dengan Bobot Normalisasi Korelasi Silang

Pemodelan GSTARX-GLS ([1,2]₁) dengan menerapkan bobot normalisasi korelasi silang mengasumsikan bahwa keterkaitan Inflasi Bahan Makanan (IBM) antar wilayah lebih dipengaruhi oleh tinggi rendahnya korelasi yang dimiliki IBM suatu lokasi dengan IBM lokasi lainnya. Perhitungan bobot korelasi silang diperoleh melalui normalisasi nilai korelasi antar lokasi pada lag yang bersesuaian. Dikarenakan model yang digunakan adalah model GSTAR- GLS ([1,2]₁) maka korelasi silang yang digunakan adalah korelasi silang pada lag 1 dan 2. Sehingga, matriks bobot normalisasi korelasi silang yang digunakan pada lag 1 dan lag 2 yaitu :

$$\mathbf{W}^1 = \begin{bmatrix} 0 & 0,35 & 0,65 \\ -0,08 & 0 & 0,92 \\ -0,57 & 0,43 & 0 \end{bmatrix} \quad \mathbf{W}^2 = \begin{bmatrix} 0 & -0,79 & 0,21 \\ 0,47 & 0 & -0,53 \\ -0,48 & -0,52 & 0 \end{bmatrix}$$

a. *Full Model*

Perhitungan estimasi parameter model GSTARX-GLS ([1,2]₁) menggunakan bobot normalisasi korelasi silang dapat dilihat pada Tabel 4.46. Estimasi parameter pada Tabel 4.46 selanjutnya dapat digunakan untuk membentuk persamaan matriks model GSTARX-GLS ([1,2]₁) menggunakan bobot normalisasi korelasi silang. yaitu :

Tabel 4.46 Estimasi Parameter *Full Model* GSTARX-GLS ([1,2]₁) dengan Bobot Normalisasi Korelasi Silang Pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,373	0,123	-3,04	0,0033
	ϕ_{11}^1	1	-0,135	0,186	-0,73	0,4704
	ϕ_{10}^2	1	-0,030	0,124	-0,24	0,8097
	ϕ_{11}^2	1	-0,063	0,160	-0,4	0,6934
Manokwari	ϕ_{10}^1	1	-0,108	0,108	-1	0,3218
	ϕ_{11}^1	1	-0,008	0,151	-0,05	0,9597
	ϕ_{10}^2	1	-0,289	0,101	-2,87	0,0053
	ϕ_{11}^2	1	-0,366	0,156	-2,34	0,022
Sorong	ϕ_{10}^1	1	0,104	0,118	0,88	0,3812
	ϕ_{11}^1	1	0,123	0,128	0,96	0,3406
	ϕ_{10}^2	1	-0,153	0,105	-1,45	0,1506
	ϕ_{11}^2	1	-0,005	0,119	-0,05	0,9638

$$\begin{aligned}
 \begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} &= \begin{bmatrix} -0,373 & 0 & 0 \\ 0 & -0,108 & 0 \\ 0 & 0 & 0,104 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\
 &+ \begin{bmatrix} -0,135 & 0 & 0 \\ 0 & -0,008 & 0 \\ 0 & 0 & 0,123 \end{bmatrix} \begin{bmatrix} 0 & 0,35 & 0,65 \\ -0,08 & 0 & 0,92 \\ -0,57 & 0,43 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\
 &+ \begin{bmatrix} -0,030 & 0 & 0 \\ 0 & -0,289 & 0 \\ 0 & 0 & -0,153 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} \\
 &+ \begin{bmatrix} -0,063 & 0 & 0 \\ 0 & -0,366 & 0 \\ 0 & 0 & -0,005 \end{bmatrix} \begin{bmatrix} 0 & -0,79 & 0,21 \\ 0,47 & 0 & -0,53 \\ -0,48 & -0,52 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}
 \end{aligned}$$

atau persamaan tersebut diatas dapat ditulis lebih sederhana sebagai berikut:

$$\begin{aligned}
 \begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} &= \left(\begin{bmatrix} -0,373 & -0,048 & -0,087 \\ 0,001 & -0,108 & -0,007 \\ -0,070 & 0,053 & 0,104 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \left(\begin{bmatrix} -0,030 & 0,050 & -0,014 \\ -0,171 & -0,289 & 0,195 \\ 0,003 & 0,003 & -0,153 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} \\
 &+ \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.
 \end{aligned}$$

Model GSTAR-GLS ([1,2]₁) untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) Kota Jayapura

$$\begin{aligned}
 n_{1,t} &= -0,373n_{1,t-1} - 0,048n_{2,t-1} - 0,087n_{3,t-1} - 0,030n_{1,t-2} + 0,050n_{2,t-2} - \\
 &0,014n_{3,t-2} + \varepsilon_{1,t}.
 \end{aligned}$$

- Model GSTARX-GLS ([1,2]₁) Kota Manokwari

$$n_{2,t} = 0,002n_{1,t-1} - 0,108n_{2,t-1} - 0,007n_{3,t-1} - 0,171n_{1,t-2} - 0,289n_{2,t-2} + 0,195n_{3,t-2} + \varepsilon_{2,t}.$$

- Model GSTARX-GLS ([1,2]₁) Kota Sorong

$$n_{3,t} = -0,070n_{1,t-1} + 0,053n_{2,t-1} + 0,104n_{3,t-1} + 0,003n_{1,t-2} + 0,003n_{2,t-2} - 0,153n_{3,t-2} + \varepsilon_{3,t}.$$

b. *Restricted Model*

Estimasi parameter pada Tabel 4.46 tidak seluruhnya signifikan pada $\alpha = 0,1$ sehingga dilakukan pemodelan ulang GSTAR-GLS ([1,2]₁) dengan mengeluarkan parameter yang tidak signifikan.

Tabel 4.47 Estimasi Parameter *Restricted Model* GSTARX-GLS ([1,2]₁) dengan Bobot Normalisasi Korelasi Silang Pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,365	0,113	-3,24	0,0018
Manokwari	ϕ_{10}^2	1	-0,278	0,096	-2,91	0,0047
	ϕ_{11}^2	1	-0,411	0,146	-2,81	0,0064

Hasil perhitungan dengan estimasi parameter model GSTAR-GLS ([1,2]₁) yang *restricted* dapat dilihat pada Tabel 4.47. Estimasi parameter pada Tabel 4.47 selanjutnya dapat digunakan untuk membentuk persamaan matriks model GSTAR-GLS ([1,2]₁) *restricted* menggunakan bobot normalisasi korelasi silang yaitu :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,365 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,278 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,411 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & -0,79 & 0,21 \\ 0,47 & 0 & -0,53 \\ -0,48 & -0,52 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,343 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ -0,192 & -0,278 & 0,219 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}.$$

Model GSTARX-GLS ([1,2]₁) *restricted* untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) Kota Jayapura

$$n_{1,t} = -0,365n_{1,t-1} + \varepsilon_{1,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ Kota Manokwari

$$n_{2,t} = -0,192n_{1,t-2} - 0,278n_{2,t-2} + 0,219n_{3,t-2} + \varepsilon_{2,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ Kota Sorong

$$n_{3,t} = \varepsilon_{3,t}.$$

Berdasarkan model GSTARX-GLS $([1,2]_1)$ *restricted* dengan bobot normalisasi korelasi silang yang terbentuk, inflasi bahan makanan di Kota Manokwari selain dipengaruhi oleh inflasi di wilayah itu sendiri dua waktu sebelumnya juga dipengaruhi oleh inflasi di Kota Jayapura dan Sorong dua waktu sebelumnya. Sedangkan, inflasi bahan makanan di Kota Jayapura tidak dipengaruhi oleh inflasi wilayah lain, namun hanya dipengaruhi oleh inflasi wilayah tersebut satu waktu sebelumnya.

4.5.3.3 Pemodelan GSTARX-GLS $([1,2]_1)$ dengan Bobot Normalisasi Inferensia Korelasi Silang Parsial

Pembentukan bobot Normalisasi Inferensia Korelasi Silang Parsial (NIKSP) pada data $n_{i,t}$ menggunakan nilai matriks *cross*-korelasi parsial antar wilayah. Sama halnya dengan pembentukan bobot NIKSP pada data inflasi bahan makanan sebelumnya, simbol skema matriks *cross*-korelasi parsial dipertimbangkan. Berdasarkan Lampiran 4 bobot normalisasi inferensia parsial korelasi silang yang digunakan pada lag yang bersesuaian, yaitu lag 1 dan 2. Pada lag 1 tidak terdapat korelasi yang signifikan terhadap batas signifikansinya sehingga bernilai nol, akan tetapi tidak demikian dengan lag 2.

$$w^1 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad w^2 = \begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ -0,5 & -0,5 & 0 \end{bmatrix}$$

a. *Full Model*

Perhitungan estimasi parameter model GSTARX-GLS $([1,2]_1)$ menggunakan bobot normalisasi inferensia parsial korelasi silang dapat dilihat pada Tabel 4.48. Estimasi parameter pada Tabel 4.48 selanjutnya dapat digunakan untuk membentuk persamaan matriks model GSTARX-GLS $([1,2]_1)$ menggunakan bobot normalisasi inferensia korelasi silang parsial.

Tabel 4.48 Estimasi Parameter *Full Model* GSTARX-GLS ([1,2]₁) dengan Bobot Normalisasi Inferensia Korelasi Silang Parsial pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,371	0,122	-3,04	0,0033
	ϕ_{10}^2	1	0,012	0,122	0,10	0,9224
	ϕ_{11}^2	1	-0,044	0,117	-0,37	0,7103
Manokwari	ϕ_{10}^1	1	-0,124	0,107	-1,16	0,2504
	ϕ_{10}^2	1	-0,239	0,101	-2,36	0,0208
Sorong	ϕ_{10}^1	1	0,118	0,113	1,04	0,3001
	ϕ_{10}^2	1	-0,195	0,103	-1,90	0,0619
	ϕ_{11}^2	1	-0,071	0,115	-0,62	0,5376

$$\begin{aligned}
 \begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} &= \begin{bmatrix} -0,371 & 0 & 0 \\ 0 & -0,124 & 0 \\ 0 & 0 & 0,118 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\
 &+ \left(\begin{bmatrix} 0,012 & 0 & 0 \\ 0 & -0,239 & 0 \\ 0 & 0 & -0,195 \end{bmatrix} \right. \\
 &\quad \left. + \begin{bmatrix} -0,044 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & -0,071 \end{bmatrix} \begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ -0,5 & -0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}
 \end{aligned}$$

atau

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,371 & 0 & 0 \\ 0 & -0,124 & 0 \\ 0 & 0 & 0,118 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \left(\begin{bmatrix} 0,012 & 0,044 & 0 \\ 0 & -0,239 & 0 \\ 0,036 & 0,035 & -0,195 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Model GSTARX-GLS ([1,2]₁) untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) Kota Jayapura

$$n_{1,t} = -0,371n_{1,t-1} + 0,012n_{1,t-2} + 0,044n_{2,t-2} + \varepsilon_{1,t}$$

- Model GSTARX-GLS ([1,2]₁) Kota Manokwari

$$n_{2,t} = -0,124n_{2,t-1} - 0,239n_{2,t-2} + \varepsilon_{2,t}$$

- Model GSTARX-GLS ([1,2]₁) Kota Sorong

$$n_{3,t} = 0,118n_{3,t-1} + 0,036n_{1,t-2} + 0,035n_{2,t-2} - 0,195n_{3,t-2} + \varepsilon_{3,t}$$

b. Restricted Model

Estimasi parameter pada Tabel 4.48 tidak seluruhnya signifikan pada $\alpha = 0,1$ sehingga dilakukan pemodelan ulang GSTARX-GLS $([1,2]_1)$ dengan mengeluarkan parameter yang tidak signifikan. Hasil perhitungan dengan estimasi parameter model GSTARX-GLS $([1,2]_1)$ yang *restricted* dapat dilihat pada Tabel 4.49.

Tabel 4.49 Estimasi Parameter *Restricted Model* GSTARX-GLS $([1,2]_1)$ dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang Pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	t-value	p-value
Jayapura	ϕ_{10}^1	1	-0,374	0,113	-3,32	0,0014
Manokwari	ϕ_{10}^2	1	-0,246	0,098	-2,50	0,0145
Sorong	ϕ_{10}^3	1	-0,165	0,098	-1,67	0,0989

Estimasi parameter pada Tabel 4.49 selanjutnya dapat digunakan untuk membentuk persamaan matriks model GSTARX-GLS $([1,2]_1)$ *restricted* menggunakan bobot normalisasi inferensia parsial korelasi silang yaitu :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,374 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,246 & 0 \\ 0 & 0 & -0,165 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Model GSTAR-GLS $([1,2]_1)$ *restricted* untuk $n_{i,t}$ inflasi bahan makanan setiap lokasi dapat dituliskan dalam bentuk persamaan sebagai berikut:

- Model GSTARX-GLS $([1,2]_1)$ Kota Jayapura
 $n_{1,t} = -0,374n_{1,t-1} + \varepsilon_{1,t}$
- Model GSTARX-GLS $([1,2]_1)$ Kota Manokwari
 $n_{2,t} = -0,246n_{2,t-2} + \varepsilon_{2,t}$
- Model GSTARX-GLS $([1,2]_1)$ Kota Sorong
 $n_{3,t} = -0,165n_{3,t-2} + \varepsilon_{3,t}$

Berdasarkan model GSTARX-GLS $([1,2]_1)$ *restricted* dengan bobot normalisasi korelasi silang yang terbentuk, tidak terdapat depensi spasial antar wilayah. Hal ini berarti dengan mengabaikan faktor jarak, inflasi bahan makanan di Kota Manokwari dipengaruhi oleh inflasi bahan makanan di wilayah itu sendiri

dua bulan sebelumnya, sedangkan Kota Jayapura dipengaruhi oleh inflasi bahan makanan di kota itu sendiri satu waktu sebelumnya.

4.5.3.4 Pemodelan GSTAR-GLS ([1,2]₁) dengan Bobot Konektifitas

Penggunaan bobot konektifitas dalam pemodelan GSTAR mengasumsikan bahwa data inflasi bahan makanan memiliki keterkaitan spasial (lokasi) yang dipengaruhi oleh konektifitas moda transportasi antar wilayahnya (w_{ij}) dengan ($i \neq j$). Matriks konektifitas antar wilayah dibuat sebagai berikut :

$$W = \begin{bmatrix} 0 & 6 & 8 \\ 6 & 0 & 8 \\ 8 & 8 & 0 \end{bmatrix}.$$

Berdasarkan hasil normalisasi bobot konektifitas diperoleh matrik bobot konektifitas sebagai berikut :

$$W' = \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix}$$

a. Full Model

Hasil perhitungan estimasi parameter pada model GSTARX-GLS ([1,2]₁) bobot konektifitas untuk pemodelan data residual inflasi bahan makanan di Pulau Papua dapat ditunjukkan pada Tabel 4.50. Hasil estimasi parameter pada Tabel 4.50 selanjutnya digunakan untuk membentuk persamaan matriks model GSTARX-GLS ([1,2]₁) bobot konektifitas pada persamaan berikut :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,340 & 0 & 0 \\ 0 & -0,184 & 0 \\ 0 & 0 & 0,162 \end{bmatrix} + \begin{bmatrix} -0,102 & 0 & 0 \\ 0 & 0,216 & 0 \\ 0 & 0 & -0,146 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \left(\begin{bmatrix} 0,011 & 0 & 0 \\ 0 & -0,245 & 0 \\ 0 & 0 & -0,216 \end{bmatrix} + \begin{bmatrix} 0,012 & 0 & 0 \\ 0 & -0,068 & 0 \\ 0 & 0 & 0,044 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0,43 & 0 & 0,57 \\ 0,5 & 0,5 & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,340 & -0,044 & -0,058 \\ 0,092 & -0,184 & 0,123 \\ -0,073 & -0,073 & 0,162 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0,011 & 0,005 & 0,007 \\ -0,029 & -0,245 & -0,039 \\ 0,002 & 0,002 & -0,216 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Tabel 4.50 Estimasi Parameter *Full Model* dari Model GSTARX-GLS ([1,2]₁) dengan Bobot Konektifitas pada Residual IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,340	0,123	-2,76	0,0074
	ϕ_{11}^1	1	-0,102	0,185	-0,55	0,5825
	ϕ_{10}^2	1	0,011	0,123	0,09	0,9293
	ϕ_{11}^2	1	0,012	0,158	0,07	0,9422
Manokwari	ϕ_{10}^1	1	-0,184	0,114	-1,62	0,1103
	ϕ_{11}^1	1	0,216	0,182	1,18	0,2405
	ϕ_{10}^2	1	-0,245	0,108	-2,28	0,0256
	ϕ_{11}^2	1	-0,068	0,178	-0,38	0,7022
Sorong	ϕ_{10}^1	1	0,162	0,114	1,41	0,1614
	ϕ_{11}^1	1	-0,146	0,118	-1,24	0,2201
	ϕ_{10}^2	1	-0,216	0,104	-2,08	0,0406
	ϕ_{11}^2	1	0,044	0,115	0,38	0,704

Model GSTAR-GLS ([1,2]₁) inflasi bahan makanan dapat ditulis dalam persamaan setiap lokasi sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) di Kota Jayapura

$$n_{1,t} = -0,340n_{1,t-1} - 0,044n_{2,t-1} - 0,058n_{3,t-1} + 0,011n_{1,t-2} + 0,005n_{2,t-2} + 0,007n_{3,t-2} + \varepsilon_{1,t}.$$

- Model GSTARX-GLS ([1,2]₁) di Kota Manokwari

$$n_{2,t} = 0,092n_{1,t-1} - 0,184n_{2,t-1} + 0,123n_{3,t-1} - 0,029n_{1,t-2} - 0,245n_{2,t-2} - 0,039n_{3,t-2} + \varepsilon_{2,t}.$$

- Model GSTARX-GLS ([1,2]₁) di Kota Sorong

$$n_{3,t} = -0,073n_{1,t-1} - 0,073n_{2,t-1} + 0,162n_{3,t-1} + 0,002n_{1,t-2} + 0,002n_{2,t-2} - 0,216n_{3,t-2} + \varepsilon_{3,t}.$$

Persamaan yang terbentuk dengan model GSTARX-GLS $([1,2]_1)$ untuk data inflasi bahan makanan di setiap lokasi dapat diketahui bahwa pengaruh data inflasi disuatu lokasi dipengaruhi oleh inflasi dilokasi tersebut atau dari lokasi lain diwaktu berbeda. Misalnya, diketahui bahwa inflasi bahan makanan di Kota Manokwari dipengaruhi oleh inflasi bahan makanan di wilayah Jayapura dan Sorong satu serta dua waktu sebelumnya.

b. *Restricted Model*

Dengan menggunakan taraf signifikan $\alpha = 0,05$ tidak semua parameter pada pemodelan GSTARX-GLS $([1,2]_1)$ dengan bobot konektifitas merupakan parameter yang signifikan. Oleh karena itu, estimasi parameter model GSTARX-GLS $([1,2]_1)$ juga dilakukan dengan menggunakan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil estimasi parameter model GSTARX-GLS $([1,2]_1)$ yang *restricted* dapat dilihat pada Tabel 4.51.

Tabel 4.51 Estimasi Parameter *Restricted Model* dari Model GSTARX-GLS $([1,2]_1)$ dengan bobot konektifitas pada $n_{i,t}$ IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,374	0,113	-3,32	0,0014
Manokwari	ϕ_{10}^2	1	-0,246	0,098	-2,50	0,0145
Sorong	ϕ_{10}^2	1	-0,165	0,098	-1,67	0,0989

Estimasi parameter yang signifikan pada taraf signifikansi $\alpha = 0,1$ seperti terlihat pada Tabel 4.51 dapat dibentuk persamaan matriks untuk model *restricted* GSTARX-GLS $([1,2]_1)$ bobot konektifitas pada persamaan berikut:

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,374 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,246 & 0 \\ 0 & 0 & -0,165 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Model GSTARX-GLS $([1,2]_1)$ untuk $n_{i,t}$ inflasi bahan makanan dapat ditulis dalam persamaan setiap lokasi sebagai berikut:

- Model GSTARX-GLS $([1,2]_1)$ Kota Jayapura

$$n_{1,t} = -0,374n_{1,t-1} + \varepsilon_{1,t} .$$

- Model GSTARX-GLS $([1,2]_1)$ Kota Manokwari

$$n_{2,t} = -0,246n_{2,t-2} + \varepsilon_{2,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ Kota Sorong

$$n_{3,t} = -0,165n_{2,t-2} + \varepsilon_{3,t}.$$

Model GSTARX-GLS $([1,2]_1)$ bobot konektifitas yang terbentuk menunjukkan bahwa inflasi bahan makanan di Kota Jayapura hanya dipengaruhi oleh diwilayahnya sendiri satu waktu sebelumnya. Sedangkan inflasi bahan makanan di Kota Manokwari dipengaruhi oleh inflasi bahan makanan di Kota Manokwari dua waktu sebelumnya.

4.5.3.5 Pemodelan GSTARX-GLS $([1,2]_1)$ dengan Bobot Matriks Segi Tiga Atas

Penggunaan bobot matriks segi tiga atas dalam pemodelan GSTAR mengasumsikan bahwa data inflasi bahan makanan memiliki keterkaitan spasial (lokasi) yang dipengaruhi oleh konektifitas moda transportasi antar wilayahnya (w_{ij}) dengan $(i \neq j)$. Namun seperti yang telah dijelaskan sebelumnya, arah jalur distribusi barang turut mempengaruhi tingkat harga disuatu daerah. Sehingga isian *cell* pada bobot merupakan hasil normalisasi bobot konektivitas, dengan batasan pada wilayah tertentu nilai matriks bobot adalah nol jika diasumsikan tidak terdapat hubungan konektivitas atas wilayah tersebut. Sehingga, bobot matriks segi tiga atas dapat dituliskan sebagai berikut:

$$W' = \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix}$$

a. Full Model

Hasil perhitungan estimasi parameter pada model GSTARX-GLS $([1,2]_1)$ matriks segi tiga atas untuk pemodelan data residual inflasi bahan makanan di Pulau Papua dapat ditunjukkan pada Tabel 4.52. Hasil estimasi parameter pada Tabel 4.50 selanjutnya digunakan untuk membentuk persamaan matriks model GSTARX-GLS $([1,2]_1)$ bobot konektifitas pada persamaan berikut :

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,370 & 0 & 0 \\ 0 & -0,150 & 0 \\ 0 & 0 & 0,125 \end{bmatrix} + \begin{bmatrix} -0,106 & 0 & 0 \\ 0 & 0,106 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\ + \left(\begin{bmatrix} 0,016 & 0 & 0 \\ 0 & -0,298 & 0 \\ 0 & 0 & -0,156 \end{bmatrix} + \begin{bmatrix} 0,033 & 0 & 0 \\ 0 & 0,252 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,43 & 0,57 \\ 0 & 0 & 0,57 \\ 0 & 0 & 0 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

atau

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \left(\begin{bmatrix} -0,370 & -0,045 & -0,060 \\ 0 & -0,150 & 0,061 \\ 0 & 0 & 0,125 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} \\ + \left(\begin{bmatrix} 0,016 & 0,014 & 0,019 \\ 0 & -0,298 & 0,144 \\ 0 & 0 & -0,156 \end{bmatrix} \right) \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix}$$

Tabel 4.52 Estimasi Parameter *Full Model* dari Model GSTARX-GLS ([1,2]₁) dengan Bobot Matriks Segi Tiga Atas pada Residual IBM

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,370	0,123	-3,02	0,0035
	ϕ_{11}^1	1	-0,106	0,186	-0,57	0,5704
	ϕ_{10}^2	1	0,016	0,122	0,13	0,8939
	ϕ_{11}^2	1	0,033	0,159	0,21	0,8349
Manokwari	ϕ_{10}^1	1	-0,150	0,111	-1,35	0,1797
	ϕ_{11}^1	1	0,106	0,252	0,42	0,6746
	ϕ_{10}^2	1	-0,298	0,106	-2,80	0,0066
	ϕ_{11}^2	1	0,252	0,234	1,08	0,2855
Sorong	ϕ_{10}^1	1	0,125	0,115	1,09	0,2813
	ϕ_{10}^2	1	-0,156	0,102	-1,52	0,1328

Model GSTARX-GLS ([1,2]₁) inflasi bahan makanan dapat ditulis dalam persamaan setiap lokasi sebagai berikut:

- Model GSTARX-GLS ([1,2]₁) di Kota Jayapura

$$n_{1,t} = -0,370n_{1,t-1} - 0,045n_{2,t-1} - 0,060n_{3,t-1} + 0,016n_{1,t-2} + 0,014n_{2,t-2} + 0,019n_{3,t-2} + \varepsilon_{1,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ di Kota Manokwari

$$n_{2,t} = -0,150n_{2,t-1} + 0,061n_{3,t-1} - 0,298n_{2,t-2} + 0,144n_{3,t-2} + \varepsilon_{2,t} .$$

- Model GSTARX-GLS $([1,2]_1)$ di Kota Sorong

$$n_{3,t} = 0,125n_{3,t-1} - 0,156n_{3,t-2} + \varepsilon_{3,t} .$$

Persamaan yang terbentuk dengan model GSTARX-GLS $([1,2]_1)$ untuk data inflasi bahan makanan di setiap lokasi dapat diketahui bahwa pengaruh data inflasi disuatu lokasi dipengaruhi oleh inflasi dilokasi tersebut atau dari lokasi lain diwaktu berbeda. Misalnya, diketahui bahwa inflasi bahan makanan di Kota Manokwari dipengaruhi oleh inflasi bahan makanan di Kota Sorong satu serta dua waktu sebelumnya.

b. Restricted Model

Dengan menggunakan taraf signifikan $\alpha = 0,05$ tidak semua parameter pada pemodelan GSTARX-GLS $([1,2]_1)$ dengan bobot konektifitas merupakan parameter yang signifikan. Oleh karena itu, estimasi parameter model GSTARX-GLS $([1,2]_1)$ juga dilakukan dengan menggunakan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil estimasi parameter model GSTARX-GLS $([1,2]_1)$ yang *restricted* dapat dilihat pada Tabel 4.53.

Tabel 4.53 Estimasi Parameter *Restricted Model* dari Model GSTARX-GLS $([1,2]_1)$ dengan Bobot Matriks Segi Tiga Atas pada $n_{i,t}$ Inflasi Bahan Makanan

Lokasi	Parameter	DF	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
Jayapura	ϕ_{10}^1	1	-0,372	0,113	-3,30	0,0015
Manokwari	ϕ_{10}^2	1	-0,231	0,098	-2,35	0,0212

Estimasi parameter yang signifikan pada taraf signifikansi $\alpha = 0,05$ seperti terlihat pada Tabel 4.53 dapat dibentuk persamaan matriks untuk model *restricted* GSTARX-GLS $([1,2]_1)$ bobot konektifitas pada persamaan berikut:

$$\begin{bmatrix} n_{1,t} \\ n_{2,t} \\ n_{3,t} \end{bmatrix} = \begin{bmatrix} -0,372 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-1} \\ n_{2,t-1} \\ n_{3,t-1} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & -0,231 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} n_{1,t-2} \\ n_{2,t-2} \\ n_{3,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \end{bmatrix} .$$

Model GSTARX-GLS $([1,2]_1)$ untuk $n_{i,t}$ inflasi bahan makanan dapat ditulis dalam persamaan setiap lokasi sebagai berikut:

- Model GSTARX-GLS $([1,2]_1)$ di Kota Jayapura

$$n_{1,t} = -0,372n_{1,t-1} + \varepsilon_{1,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ di Kota Manokwari

$$n_{2,t} = -0,231n_{2,t-2} + \varepsilon_{2,t}.$$

- Model GSTARX-GLS $([1,2]_1)$ di Kota Sorong

$$n_{3,t} = \varepsilon_{3,t}.$$

Model GSTAR-GLS $([1,2]_1)$ bobot konektifitas yang terbentuk menunjukkan bahwa inflasi bahan makanan di Kota Jayapura hanya dipengaruhi oleh inflasi di Kota Jayapura satu bulan sebelumnya. Demikian juga inflasi bahan makanan di Kota Sorong dipengaruhi oleh inflasi bahan makanan di Kota Manokwari satu waktu sebelumnya. Hasil estimasi parameter dari *model restricted* menunjukkan bahwa hipotesa awal terkait inflasi bahan makanan di wilayah Papua yang dipengaruhi oleh jalur distribusi transportasi laut tidak terbukti.

4.5.4. *Diagnostic Checking* dan Peramalan dengan Model GSTARX-GLS $([1,2]_1)$

Pengujian residual *white noise* pada tahapan *diagnostic checking* pemodelan GSTAR-GLS $([1,2]_1)$ akan dilkaskan pada tahapan berikutnya. Namun demikian model GSTAR-GLS $([1,2]_1)$ dengan masing-masing bobot lokasi yang diperoleh tetap digunakan untuk peramalan tahap kedua. Hasil peramalan tahap kedua akan digunakan pada tahap selanjutnya.

4.6 Pemodelan GSTARX

Pemodelan GSTARX merupakan kombinasi dari hasil peramalan tahap pertama dengan menggunakan fungsi transfer multi input dan peramalan tahap kedua dengan menggunakan model GSTAR-GLS $([1,2]_1)$. persamaan yang digunakan untuk menghirung peramalan GSTARX yaitu :

$$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{n}_{i,t},$$

dengan

$\hat{Y}_{i,t}$ adalah hasil ramalan ke- t di lokasi i dari model GSTARX,

$\hat{y}_{i,t}$ adalah hasil ramalan ke- t di lokasi i pada tahap pertama,

$\hat{n}_{i,t}$ adalah hasil ramalan ke- t di lokasi i pada tahap kedua.

4.6.1. Diagnostic Checking Model GSTARX

Pengujian asumsi residual *white noise* pada model GSTARX dapat dilakukan dengan pemodelan ulang *residual* dan pengecekan letak nilai AIC terkecil. Lampiran 3 dan 4 menunjukkan asumsi residual terkecil telah berada pada lag AR(0) dan MA(0). Hal ini berarti bahwa asumsi residual *white noise* telah terpenuhi sehingga layak digunakan untuk peramalan.

4.6.2. Pemilihan Model Terbaik pada Model GSTARX

Setelah memperoleh pemodelan GSTARX dan pengujian kelayakan model selanjutnya dilakukan penghitungan akurasi peramalan data *in-sample* dan *out-sample*. Jumlah data *in-sample* adalah sebanyak 84 observasi sedangkan data *out-sample* sebanyak 12 observasi. Akurasi hasil peramalan didasarkan pada nilai RMSE terkecil. Hasil penghitungan RMSE *in-sample* untuk *full* dan *restricted model* GSTARX dapat kita lihat pada Tabel 4.54.

Tabel 4.54 Nilai RMSE *In-Sample* menurut bobot lokasi pada Pemodelan GSTARX-GLS ([1,2]₁)

Model	Bobot Lokasi	Jayapura	Manokwari	Sorong	Rata-rata RMSE
<i>Full Model</i>	Invers Jarak	3,069	2,685	2,192	2,649
	NKS	3,055	2,600	2,194	2,616
	NIKS	3,070	2,700	2,205	2,658
	Konektivitas	3,063	2,674	2,184	2,641
	Segi Tiga Atas	3,066	2,679	2,172	2,639
<i>Restricted Model</i>	Invers Jarak	3,009	2,688	2,175	2,624
	NKS	3,009	2,585	2,187	2,594
	NIKS	3,010	2,670	2,175	2,618
	Konektivitas	3,010	2,670	2,175	2,618
	Segi Tiga Atas	3,009	2,670	2,187	2,622

Berdasarkan Tabel 4.54, secara umum RMSE *in-sample* model *restricted* GSTARX-GLS ([1,2]₁) dengan bobot normalisasi korelasi silang memberikan nilai RMSE yang kecil. Model tersebut secara umum dapat memodelkan dengan lebih baik data inflasi bahan makanan pada tiga lokasi di Papua. Namun jika

diperhatikan lebih seksama, pemilihan bobot terbaik terhadap masing-masing wilayah, model *restricted* GSTARX-GLS $([1,2]_1)$ dengan bobot normalisasi korelasi silang cukup baik memodelkan inflasi bahan makanan di Kota Jayapura dan Manokwari. Model *full* GSTARX-GLS $([1,2]_1)$ dengan bobot segi tiga atas lebih baik memodelkan inflasi di Kota Sorong. Pengaruh efek spasial pada model tidak sepenuhnya ada untuk seluruh wilayah. Hal ini sesuai dengan identifikasi deskriptif awal, pada lag 0 skema MCCF, korelasi antar wilayah hanya terjadi pada waktu yang sama antara wilayah Manokwari dan Sorong saja. Namun efek efek spasial pada wilayah Manokwari masih berlanjut hingga dua waktu setelahnya.

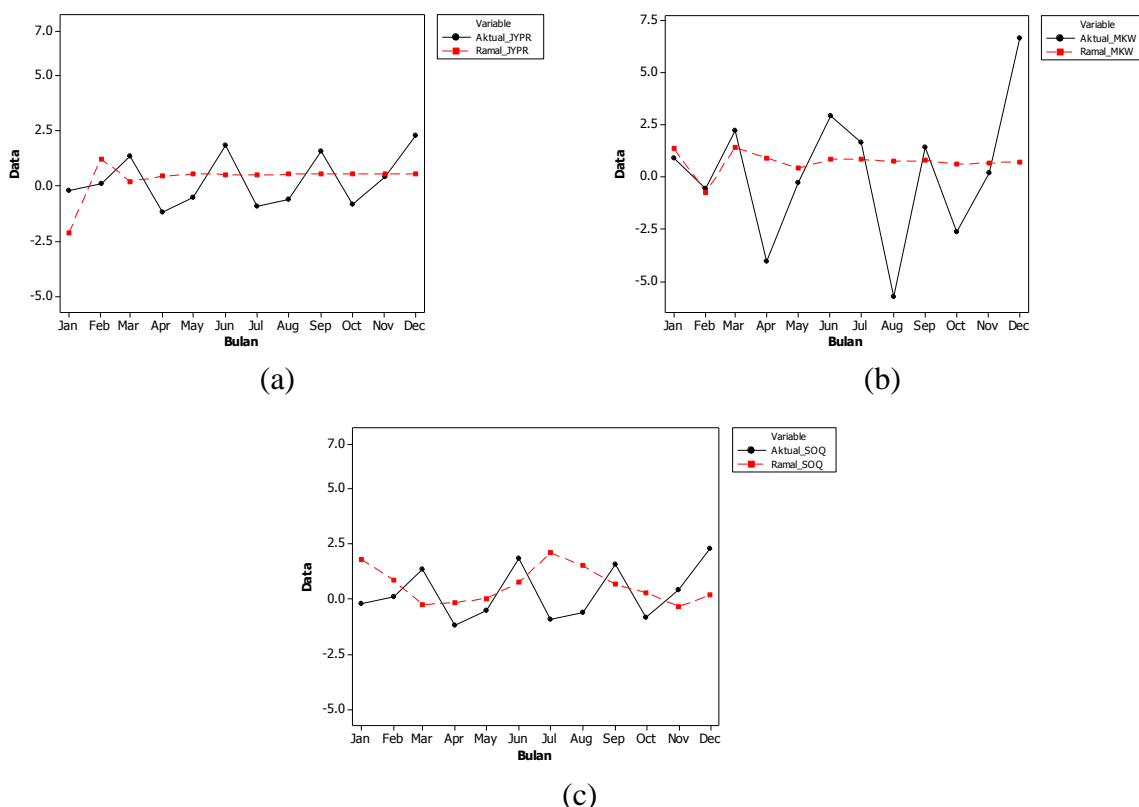
Tabel 4.55 Nilai RMSE *Out-Sample* menurut bobot lokasi pada Pemodelan GSTARX -GLS $([1,2]_1)$

Model	Bobot Lokasi	Jayapura	Manokwari	Sorong	Rata-rata RMSE
<i>Full Model</i>	Invers Jarak	1,312	3,228	1,614	2,051
	NKS	1,319	3,159	1,585	2,021
	NIKS	1,353	3,186	1,650	2,063
	Konektivitas	1,291	3,223	1,572	2,029
	Segi Tiga Atas	1,368	3,187	1,648	2,068
<i>Restricted Model</i>	Invers Jarak	1,325	3,188	1,610	2,041
	NKS	1,309	3,175	1,602	2,028
	NIKS	1,324	3,188	1,610	2,041
	Konektivitas	1,324	3,188	1,610	2,041
	Segi Tiga Atas	1,320	3,186	1,602	2,036

Nilai RMSE *out-sample* dapat memberikan informasi mengenai kekonsistenan model dalam melakukan peramalan suatu deret data. Berdasarkan Tabel 4.55 diketahui secara umum bahwa RMSE *full model* GSTARX-GLS $([1,2]_1)$ bobot normalisasi korelasi silang memberikan nilai RMSE *out-sample* terkecil. Hasil peramalan tersebut menunjukkan bahwa keterkaitan antar wilayah dipengaruhi oleh besarnya korelasi infasi bahan makanan di Pulau Papua pada lag yang bersesuaian. Pemilihan model dengan bobot terbaik pada masing-masing wilayah menunjukan *full* model GSTARX-GLS $([1,2]_1)$ dengan bobot

konektivitas lebih baik dalam meramalkan data inflasi bahan makanan di Kota Sorong dan Jayapura. *Full Model* GSTARX-GLS $([1,2]_1)$ dengan bobot normalisasi korelasi silang cukup baik dalam meramalkan inflasi di Kota Manokwari.

Hasil tersebut dapat menjadi bukti empiris bahwa harga bahan pokok kelompok bahan makan Kota Sorong, sangat bergantung pada konektivitas transportasi laut. Pemerintah melalui program *Materplan* Percepatan dan Perluasan Pembangunan Ekonomi Indonesia (MP3EI) menjadikan Pelabuhan Sorong dan Jayapura sebagai Koridor Ekonomi Papua. Fokus program tersebut adalah mempersiapkan konektivitas berbagai pelabuhan di Kepulauan Maluku – Papua sehingga terbangunnya kawasan sentra produksi pangan dan memutus rantai distribusi yang panjang. Meskipun demikian, pada bulan ketika terdapat hari raya keagamaan stok komoditas pangan perlu diperhatikan agar seimbang sehingga kenaikan harga pangan tidak begitu tinggi.



Gambar 4.32 Perbandingan Inflasi Bahan Makanan Aktual dan Hasil Peramalan Pemodelan GSTARX-GLS $([1,2]_1)$ Data *Out-sample* (a) Jayapura (b) Manokwari dan (c) Sorong

Plot time series antara data aktual per wilayah dengan peramalan model GSTARX-GLS $([1,2]_1)$ yang terbaik dapat dilihat pada Gambar 4.32. Plot tersebut menunjukkan secara umum bahwa hasil ramalan inflasi bahan makanan di tiga kota di Pulau Papua masih belum dapat meramalan dengan baik. Model GSTAR merupakan model dengan basis mean (rata-rata) sehingga ramalan beberapa waktu kedepan bergerak disekitar rata-rata data. Fluktuasi data aktual menyebabkan plot ramalan model GSTARX-GLS $([1,2]_1)$ dengan bobot terbaik terhadap data aktual kurang dapat mendekati nilai aktualnya terutama untuk wilayah Manokwari.

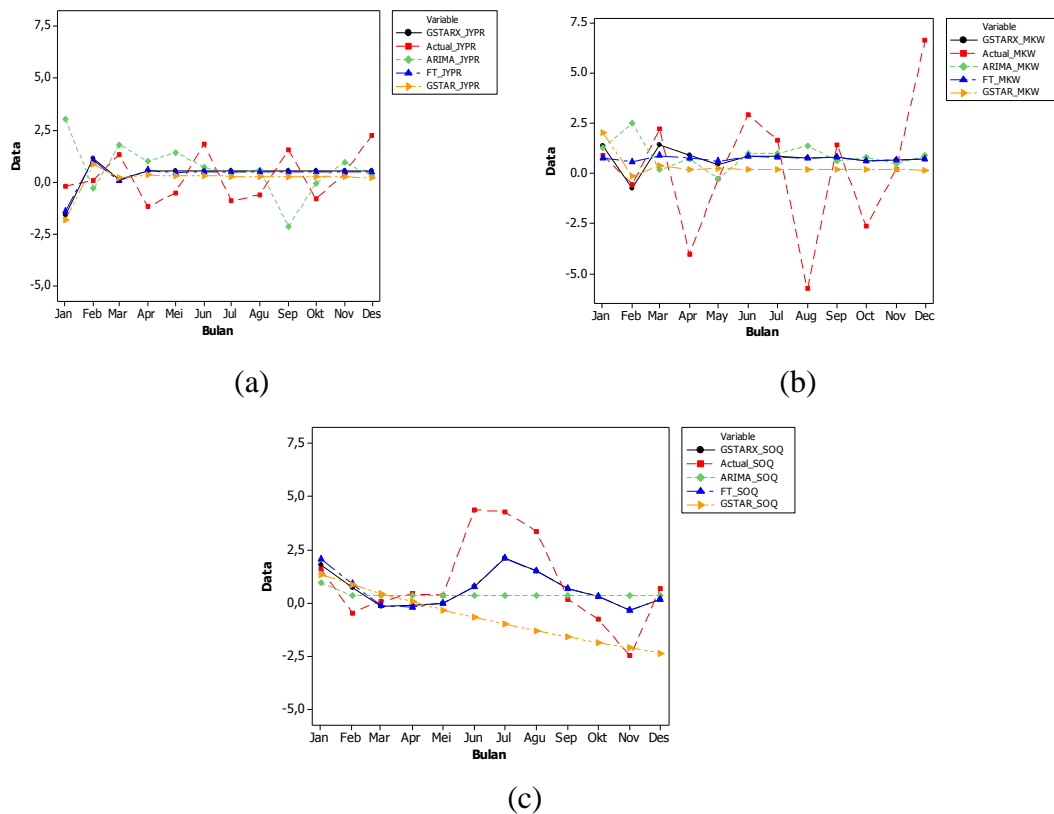
Beberapa penyebab mengapa fluktuasi inflasi kelompok bahan makanan sangat tinggi di wilayah Papua disebabkan oleh pergerakan harga yang fluktuatif pada pengeluaran pada sub kelompok ikan segar dan bumbu-bumbuan. BPS sudah mencoba memotret perubahan tersebut dengan jadwal pencacahan yang lebih intens sehingga lebih menggambarkan pergerakan perubahan harganya. Namun di Pulau Papua andil inflasi yang sangat besar pada kedua sub kelompok tersebut menyebabkan perubahan kecil pada harga (naik/turun) dapat menyebabkan kenaikan atau penurunan inflasi yang sangat signifikan. Pemerintah perlu menjamin ketersediaan komoditas sehingga harga relatif lebih stabil.

4.7 Perbandingan Hasil Pemodelan ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS $([1,2]_1)$ terhadap IBM di Pulau Papua

Perbandingan hasil pemodelan data *out-sample* ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS $([1,2]_1)$ dapat dilakukan akurasi pemodelan terhadap data aktual inflasi bahan makanan di masing-masing wilayah. Hasil perbandingan ramalan data *out-sample* dengan ke empat metode tersebut hingga 12 bulan ke depan dapat dilihat pada Gambar 4.33.

Terlihat hasil ramalan kurang cukup mengikuti pola data yang cenderung fluktuatif. Pola data inflasi yang random dengan fluktuasi yang tinggi pada Kota Manokwari menunjukkan ketidakstabilan harga pangan. Penurunan harga yang tajam atau kenaikan harga pada kelompok harga ikan segar lebih disebabkan oleh ketersediaan hasil tangkapan nelayan pesisir di.pasaran. berdasarkan hasil SBH 2012, share sub kelompok tertinggi pada kelompok bahan makanan adalah sub kelompok ikan segar. Sekitar 22% - 23% pengeluaran bahan makanan

dibelanjakan untuk komoditas ikan segar. Dengan demikian, kenaikan harga yang relatif sedikit dapat memicu kenaikan yang signifikan pada inflasi bahan makanan. Penyebab lainnya yaitu pada bulan-bulan tertentu, terutama memasuki hari raya keagamaan lonjakan harga terjadi hampir diseluruh kelompok bahan makanan. Pada umumnya lonjakan tertinggi terjadi pada bulan Desember saat memasuki hari raya natal.



Gambar 4.33 Perbandingan Time Series Plot Data IBM Aktual dengan Peramalan Model ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS ($[1,2]_1$) Data *Out-sample* (a) Jayapura (b) Manokwari dan (c) Sorong

Perbandingan nilai RMSE data *out-sample* dari ke empat pemodelan tersebut dapat dilihat pada Tabel 4.56. Peramalan inflasi bahan makanan di Kota Jayapura lebih baik dimodelkan dengan menggunakan model Fungsi Transfer. Sedangkan Peramalan inflasi bahan makanan di Kota Manokwari dan Sorong lebih baik dimodelkan dengan menggunakan model GSTARX-GLS ($[1,2]_1$). Faktor cuaca yang menjadi fokus topik penelitian mendukung fakta bahwa inflasi bahan makanan di Kota Manokwari dan Sorong di pengaruhi oleh faktor cuaca,


yaitu Kecepatan Angin. Identifikasi awal pada skema MCCF tuut mendukung bahwa pada waktu yang sama tidak terdapat keterkaitan antara wilayah Jayapura dengan dua wilayah lainnya. Kecepatan angin sebagai variabel eksogen lebih dapat mempengaruhi ketersediaan stok ikan segar menyebabkan inflasi bahan makanan sangat fluktuatif. Frekuensi perjalanan kapal laut setiap bulan antar wilayah menyebabkan keterkaitan tersebut lebih tinggi terutama antara Kota Manokwari dan Sorong. Posisi wilayah Manokwari yang berada dalam satu provinsi dengan Kota Sorong menyebabkan beberapa pemberlakuan kebijakan harga pangan sama untuk kedua wilayah tersebut.

Tabel 4.56 Nilai RMSE Data *Out-Sample* Hasil Pemodelan ARIMA, Fungsi Transfer, GSTAR-GLS (1_1) dan GSTARX-GLS ($[1,2]_1$) pada data IBM di Pulau Papua

Model	Kota		
	Jayapura	Manokwari	Sorong
ARIMA	1,875	3,387	2,071
Fungsi Transfer	1,255	3,174	1,602
GSSTAR-GLS (1_1)	1,288	3,208	2,059
GSSTARX-GLS ($[1,2]_1$)	1,319	3,159	1,585

Bukti empiris menyatakan bahwa model Fungsi Transfer lebih baik dalam meramal inflasi bahan makanan di Kota Jayapura sesuai dengan kenyataan dilapangan. Komoditas yang mempengaruhi inflasi bahan makanan di Kota Jayapura yaitu kelompok ikan segar, bumbu-bumbuan dan sayuran. Ketersediaan komoditas bumbu-bumbuan seperti bawang merah masih bergantung pada pengiriman dari luar pulau meskipun produsen lokal sudah membudidayakannya. Akibatnya, keterlambatan pengiriman barang dari luar pulau menyebabkan lonjakan tinggi terhadap kenaikan harga tersebut dipasaran. Meskipun distribusi komoditas tersebut melalui kapal laut, namun efek dependensi Kota Jayapura dengan Kota Sorong dan Manokwari kecil. Kapal yang berasal dari Kota Manokwari atau Sorong masih harus singgah dua pelabuhan lainnya sebelum berlabuh di Kota Jayapura.

Faktor yang mempengaruhi harga terhadap dua komoditas lainnya lebih disebabkan oleh faktor cuaca. Hal ini karena komoditas sayuran dan ikan segar dapat dipenuhi oleh produsen lokal. Lonjakan tinggi terhadap kenaikan harga umumnya dipengaruhi oleh faktor cuaca yaitu kecepatan angin dan intensitas hujan yang tinggi.



Gambar 4.34 Perbandingan RMSE Model ARIMA, Fungsi Transfer, GSTAR dan GSTARX Ramalan IBM di Pulau Papua

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan, maka kesimpulan yang diperoleh dari penelitian ini sebagai berikut:

1. Data inflasi bahan makanan antar lokasi saling berkorelasi dengan model GSTARX-GLS yang terbentuk $([1,2]_1)$. Berdasarkan perbandingan RMSE *out-sample* menunjukkan *full* model GSTARX-GL $([1,2]_1)$ dengan bobot normalisasi korelasi silang cukup baik dalam memodelkan inflasi bahan makan di Pulau Papua. Inflasi bahan makanan di Pulau Papua selain di pengaruhi oleh faktor cuaca juga dipengaruhi oleh faktor keterkaitan korelasi antar inflasi bahan makanan di Pulau Papua. Berdasarkan perbandingan bobot per wilayah diperoleh kesimpulan *full* model GSTARX-GLS $([1,2]_1)$ dengan bobot konektivitas lebih baik dalam meramalkan data inflasi bahan makanan di Kota Sorong dan Jayapura. *Full* Model GSTARX-GLS $([1,2]_1)$ dengan bobot normalisasi korelasi silang cukup baik dalam meramalkan inflasi di Kota Manokwari.
2. Hasil Peramalan *full model* GSTARX-GL $([1,2]_1)$ pada data *in-sample* inflasi bahan makanan di masing-masing wilayah cukup baik karena nilai RMSE peramalan berada di bawah nilai standar deviasi data *out-sample*.
3. Berdasarkan perbandingan nilai RMSE *out-sample* terkecil pada beberapa metode maka dapat disimpulkan :
 - a. Model Fungsi Transfer merupakan model peramalan IBM terbaik di Kota Jayapura. Peramalan IBM di Kota Jayapura hanya dipengaruhi oleh faktor cuaca tanpa melibatkan dependensi antar wilayah.
 - b. Model GSTARX-GLS $([1,2]_1)$ dengan bobot normalisasi korelasi silang merupakan model peramalan IBM terbaik di Kota Manokwari. Peramalan IBM di Kota Manokwari selain dipengaruhi oleh faktor cuaca juga turut dipengaruhi oleh dependensi antar wilayah. Dependensi tersebut merepresentasikan korelasi inflasi antar wilayah.

- c. Model GSTARX-GLS ([1,2]₁) dengan bobot normalisasi korelasi silang merupakan model peramalan IBM terbaik di Kota Sorong. Peramalan IBM di Kota Sorong selain dipengaruhi oleh faktor cuaca juga turut dipengaruhi oleh dependensi antar wilayah.
4. Faktor cuaca yang mempengaruhi inflasi bahan makanan di Pulau Papua adalah kecepatan angin. Fluktuasi data setiap bulan mempengaruhi penangkapan komoditas ikan segar yang memiliki andil terbesar dalam pembentuk inflasi bahan makanan.
5. Implementasi bobot spasial matriks segi tiga atas pada model GSTAR tanpa melibatkan variabel eksogen cukup baik dalam meramalkan inflasi bahan makanan di Pulau Papua. Namun tidak demikian dengan penggunaan bobot konektivitas pada model GSTAR ataupun GSTARX yang tidak memberikan hasil peramalan yang lebih baik dibandingkan dengan bobot lainnya

5.2 Saran

Saran yang diberikan oleh peneliti untuk penelitian selanjutnya terkait pemodelan GSTARX adalah penggunaan variabel prediktor metrik berupa faktor cuaca bukan merupakan data re-analisis. Karena sampai saat ini ketersediaan data faktor cuaca hasil pengukuran berskala metrik masih sangat terbatas, maka perlu mencari sumber referensi data lain. Selain itu, perlu dilakukan kajian khusus berupa simulasi pemodelan GSTAR atau GSTARX berdasarkan bobot spasial yang turut memperhitungkan arah interaksi antar wilayah. Pada penelitian ini hanya mengaplikasikan matriks bobot spasial yang memperhitungkan arah interaksi antar wilayah berdasarkan asumsi awal peneniliti. Sehingga pemodelan pada matriks bobot spasial yang memperhitungkan arah interaksi memberikan hasil peramalan yang tidak lebih baik dibanding model lainnya. Saran untuk penelitian selanjutnya yang menggunakan data inflasi bahan makanan di Pulau Papua maka perlu menambah jumlah observasi karena deret data yang dianalisis memiliki fluktuasi yang relatif tinggi.

DAFTAR PUSTAKA

- Aidoo, E. (2010). *Modelling and Forecasting Inflation Rates in Ghana (an Application of SARIMA Models) [Thesis]*. Sweden: Hogskolan Dalarna.
- Altissimo, F., Mojon, B., & Zaffaroni, P. (2009). Can Aggregation Explain the Persistence of inflation. *Journal of Monetary Economics*.
- Aron, J., & Muellbauer, J. (2103). New Methods for Forecasting Inflation, Applied to the US. *Oxford Bulletin of Economics and Statistics*.
- Badan Ketahanan Pangan Kementrian Pertanian (BKPKP). (2015). *Laporan Akhir Kawasan Mandiri Pangan Tahun 2015*. Jakarta: BKPKP.
- Badan Pusat Statistik (BPS). (2013). *Diagram Timbang Indeks Harga Konsumen (Buku 1)*. Jakarta: Badan Pusat Statistik.
- Badan Pusat Statistik (BPS). (2016). *Indeks Harga Konsumen 82 Kota di Indonesia*. Jakarta: Badan Pusat Statistik.
- Bank Indonesia (BI). (2013). *Bank Indonesia dan Inflasi*. Retrieved 08 29, 2016, from <http://www.bi.go.id/id/moneter/inflasi/bi-dan-inflasi/Contents/Default.aspx>
- Bank Indonesia (BI). (2013). *Tujuan Kebijakan Moneter Bank Indonesia*. Retrieved September 28, 2016, from <http://www.bi.go.id/id/moneter/tujuan-kebijakan/Contents/Default.aspx>
- Bank Indonesia (BI). (2014). *Kajian Ekonomi Regional Triwulan IV-2013*. Jayapura: Bank Indonesia.
- Bank Indonesia. (2015). *Kajian Ekonomi dan Keuangan Daerah Tw IV 2015 Prov Papua Barat*. Manokwari: Bank Indonesia.
- Borovkova, S., Lopuhaa, H., & Ruchjana, B. (2008). Consistency and Asymptotic Normality of Least Square Estimator in Generalized Star Model. *Statistica Neerlandica*, 482 - 508.
- Central Bank of The Republic of Turkey. (2013). Short-Term Inflation Forecasting Model for Turkey and a Forecast Combination Analysis. *Economic Modelling*.

- Chen, Y.-c., Turnovsky, S. J., & Zivot, E. (2014). Forecasting Inflation Using Comodity Price Aggregate. *Journal Of Econometric*.
- Czudaj, R. (2011). P-star in Time of Crisis - Forecasting Inflation for The Euro Area. *Economic System*.
- Gonzalez, A., Hubrich, K., & Teravista, T. (2010). Forecasting Inflation With Gradual Regime Shift and Exogenous Information. *International Journal Of Forecasting*.
- Greene, W. (2007). *Economic Analysis, Sixth Edition* . New Jersey: Prentice Hall.
- Grossmann, A., Love, I., & Orlov, A. G. (2014). The Dynamics of Exchange Rate Volatility : A Panel Var Approach. *Journal of International Financial Market, Institution & Money*.
- Guerello, C. (2014). The Cost of Deviating from the Optimal Monetary Policy : A Panel VAR Analysis. *Journal of Financial Stability*.
- Hardle, W. K., & Cabrera, B. L. (2012). The Implied Market Price of Weather Risk. *Applied Mathematical Finance*, 1.
- Hasbullah, J. (2012). *Tangguh Dengan Statistik*. Jakarta: Insan Cendikia.
- Hassani, H., Heravi, S., & Zhigljavsky, A. (2009). Forecasting European Industrial Production with Singular Spectrum Analysis. *International Journal of Forecasting*, 107.
- Huitema, B. E., Houten, R. V., & Manal, H. (2014). Time Series Intervention Analysis of Pedestrian Countdown Timer Effect. *Accident Analysis and Prevention*.
- Hutabarat, S., & Evans, S. (1985). *Pengantar Oseanografi*. Jakarta: UI Press.
- Jassen, P. E., Hansen, B., & Bidlot, J. R. (1997). Verification of The ECMWF Wave Forecasting System Againt Buoy and Altimeter Data. *American Meteorologi Society*, 769.
- Jaworski, P., & Pitera, M. (2013). On SPatial Contagion and Multivariate GARCH Model. *Wiley*, 1.
- Kementrian Dagang Indonesia (KADIN). (2011, Juli 26). Distribusi dan Penyediaan Pangan. Jakarta.

- Khoshnevisan, B., Rafiee, S., Imod, M., & Mousazadeh, H. (2014). Development of an Intelligent System Based on ANFIS for Predicting Wheat Grain Yield on Basis of Energy Inputs. *Information Processing in Agriculture*.
- Lesage, J. P., & Polasek, W. (2008). Incorporating Transportation Network Structure in Spatial Econometric Models of Commodity Flows. *Spatial Econometric Analysis*, 266-230.
- Lim, C., Mc Aleer, M., & Min, J. C. (2008). ARMAX Modelling of International Tourist Demand. *Mathematic and Computers in Simulation*.
- Lipsey, R. G., Purvis, D. D., Steiner, P. O., & Courant, P. N. (1992). *Makroekonomi*. Jakarta: Binarupa Aksara.
- Mulyaningsih, T., Ruchjana, B. N., & Soemartini. (2013, 01). *Pendekatan Model Time Series untuk Pemodelan Inflasi Beberapa Kota di Jawa Tengah*. Retrieved 08 11, 2016, from pustaka.unpad.ac.id: http://pustaka.unpad.ac.id/wp-content/uploads/2015/01/Makalah-Semnas_Tri-Mulyaningsih_140720131.pdf
- Muryanto. (2016). *Pemodelan GSTAR-X untuk peramalan Indeks Harga Konsumen di Kalimantan*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Nawisworo, & Eva, Y. (2006). *Perencanaan Sistem Perlindungan Pantai Kampung Cina Tua Provinsi Irian Jaya Tengah [Tugas Akhir]*. Bandung: Universitas Diponegoro.
- Onder, O. (2004). Forecasting Inflation in Emerging Market by Using Philips Curve and Alternative Time Series Model. *Taylor % Francis*.
- Pfeifer, P., & Deutsch, S. (1980a). A Three Stage Iterative Procedure For SPace Time Modeling. *Technometrics*, Vol 22, 35-47.
- Pfeifer, P., & Deutsch, S. (1980b). Identification and Interpretation of First Order Space Time ARMA Model. *Technometrics*, 397-408.
- Pincheeira, P. M., & Medel, C. A. (2015). Forecasting Inflation with a Random Walk. *Prague International Academic Conference*. Prague.
- Posedel, P. (2005). Properties and estimation of GARCH (1,1) Model. *Metodoloski Zvezki*, 243-257.

- PT.PELNI (Persero). (2016). *Jadwal Kapal dan Pemesanan Tiket*. Retrieved 09 28, 2016, from <https://www.pelni.co.id/reservation/schedule/>
- Pusat Penelitian dan Pengembangan Perhubungan Laut (P4L). (2012). *Pengembangan Transportasi Laut di Kawasan Timur Indonesia dalam Upaya Mendukung Kelancaran Distribusi Bahan Pokok dan Ketahanan Pangan*. Jakarta: Departemen Perhubungan.
- Raharjo, J. S. (2013). Model Artificial Neural Network Berbasis Particle Swarm Optimization untuk Prediksi Laju Inflasi. *Jurnal Sistem Komputer*, 1.
- Rousant, O., Laurent, J.-P., Bay, X., & Carraro, L. (2003). A Bootsrap Approach To The Price Uncertainty of Weather Derivatives.
- Ruchjana, B. N. (2002). Suatu Model Generalized Space Time Autoregressive dan Penerapannya pada Produksi Minyak Bumi. Bandung: Program Doktor Institut Teknologi Bandung.
- Saz, G. (2011). The Efficacy of SARIMA Model for Forecasting Inflation Rates in Developing Countries (The Case for Turkey). *International Research Journal of Finance and Economics*.
- Srivastava, V., & Dwivedi, T. (1979). Estimation of Seemingly Unrelated Regression Equation; A Brief Syuvey. *Jurnal of Econometrics*, 15-32.
- Suara Pembaruan. (2013, Oktober 16). Retrieved September 6, 2016, from Mewujudkan Indonesia sebagai Negara Maritim yang Maju: <http://www.beritasatu.com/industri-perdagangan/144599-mewujudkan-indonesia-sebagai-negara-maritim-yang-maju.html>
- Suhartono, & Atok, R.M. (2005). Perbandingan antara Model VARIMA dan GSTAR untuk Peramalan Data Deret Waktu dan Lokasi. *Seminar Nasional Statistik*. Surabaya: Institut Teknologi Sepuluh Nopember .
- Suhartono, & Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Jurnal Of Quantitative Methods*, (pp. 45-53).
- Sukirno, S. (2008). *Makro Ekonomi (Teori Pengantar)*. Jakarta: PT. Raja Grafindo.
- Terzi, S. (1995). Maximum Likelihood Estimation of a GSTAR (1:1) Model. *Statistical Method and Application* , 377-393.

- The European Centre for Medium-Range Weather Forecasts (ECMWF). (2011). *User Guide to ECMWF Forecast Product*. Shinfield Park (Reading) : ECMWF.
- Tiao, G. C., & Box, G. E. (1981). *Modeling Multiple Time Series with Application*. New York: JSTOR.
- Universitas Negeri Papua (UNIPA). (2005). *Laporan Akhir Kajian Kapasitas Pemerintah Daerah Delapan Kabupaten Terpilih Di Papua [kerjasama dengan UNDP-Papua Capacity Needs]*. Manokwari: UNIPA.
- Wahyuningrum, S. (2014). *Model G-STAR-GLS untuk Peramalan Spatio Temporal*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Wei, W. S. (2006). *Analisis Univariate and Multivariate Time Series*. New York: Springer.
- Wutsqa, D., & Suhartono. (2010). Peramalan Deret Waktu Multivariate Seasonal pada Data Pariwisata dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar*, 101-109.
- Wutsqa, D., Suhartono, & Sutijo, B. (2010). Generalized Space Time Autoregressive Modelling. *The 6th IMT-GT Conference on Mathematics Statistics and Its Application* (pp. 752-761). Kuala Lumpur: University Tuanku Abdul Rahman.
- Xiumei, S., Min, Z., & Ming, Z. (2011). Empirical Study on The Relationship Between Economics Growth and Carbon Emmision in Resource-Dependent Cities Based on Vector Autoregressive Model. *Energy Procedia*.
- Zellner, A. (1962). An Efficient Method of Estimating Seemingly Unrelated Regression and test for Aggregation Bias. *Journal of The American Statistical Association*, 346-368.

LAMPIRAN

Lampiran 1 Output SAS Hasil Estimasi Parameter *Full Model* GSTAR-GLS (1₁) pada Data Inflasi Bahan Makanan di Pulau Papua

a. Bobot Invers Jarak

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y1_t1	1	-0.23172	0.113223	-2.05	0.0439
V1_t1	1	0.188891	0.136283	1.39	0.1695
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y2_t1	1	-0.00595	0.108938	-0.05	0.9566
V2_t1	1	0.273627	0.142405	1.92	0.0582
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y3_t1	1	0.966716	0.030416	31.78	<.0001
V3_t1	1	-0.02103	0.032073	-0.66	0.5139

b. Bobot Normalisasi Korelasi Silang

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y1_t1	1	-0.18002	0.112431	-1.60	0.1132
V1_t1	1	0.060150	0.189466	0.32	0.7517
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y2_t1	1	-0.05765	0.109052	-0.53	0.5985
V2_t1	1	0.402215	0.160760	2.50	0.0144
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y3_t1	1	0.965744	0.029200	33.07	<.0001
V3_t1	1	-0.05838	0.038919	-1.50	0.1375

c. Bobot Normalisasi Inferensia Parsial Korelasi Silang

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y1_t1	1	-0.23199	0.110663	-2.10	0.0392
V1_t1	1	-0.15578	0.134661	-1.16	0.2507

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y2_t1	1	0.048342	0.104542	0.46	0.6450

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y3_t1	1	0.957780	0.029729	32.22	<.0001
V3_t1	1	-0.00688	0.024434	-0.28	0.7791

d. Bobot Konektivitas

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y1_t1	1	-0.23783	0.111825	-2.13	0.0365
V1_t1	1	0.264807	0.156435	1.69	0.0943

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y2_t1	1	-0.03417	0.107962	-0.32	0.7524
V2_t1	1	0.398259	0.159694	2.49	0.0147

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y3_t1	1	0.971327	0.030549	31.80	<.0001
V3_t1	1	-0.01659	0.032219	-0.51	0.6080

e. Bobot Segi Tiga Atas

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y1_t1	1	-0.26303	0.110624	-2.38	0.0198
V1_t1	1	0.287244	0.157023	1.83	0.0710

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y2_t1	1	-0.00527	0.106280	-0.05	0.9606
V2_t1	1	0.525850	0.228477	2.30	0.0239

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Y3_t1	1	0.968736	0.029457	32.89	<.0001

Lampiran 2 Nilai AIC Residual Model GSTAR-GLS (1_1) (*Restricted Model*) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua

Bobot Lokasi	Lag	MA(0)	MA(1)	MA(2)
Invers Jarak	AR(0)	3,029	3,242	3,077
	AR(1)	3,137	3,339	3,236
Normalisasi Korelasi Silang	AR(0)	3,027	3,232	3,067
	AR(1)	3,128	3,335	3,234
Normalisasi Inferensia Korelasi Silang	AR(0)	6,335	6,674	6,668
	AR(1)	3,153	3,427	3,250
Konektivitas	AR(0)	2,991	3,179	3,094
	AR(1)	3,090	3,314	3,275
Segi Tiga Atas	AR(0)	3,007	3,239	3,131
	AR(1)	3,113	3,333	3,277

Lampiran 3 Nilai AIC Residual Model GSTARX-GLS ($[1,2]_1$) (*Full Model*) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua

Bobot Lokasi	Lag	MA(0)	MA(1)	MA(2)
Invers Jarak	AR(0)	5,241	5,596	5,784
	AR(1)	5,458	5,731	5,932
Normalisasi Korelasi Silang	AR(0)	5,166	5,559	5,790
	AR(1)	5,416	5,671	5,895
Normalisasi Inferensia	AR(0)	5,259	5,623	5,797
Korelasi Silang	AR(1)	5,481	5,757	5,920
Konektivitas	AR(0)	5,209	5,571	5,772
	AR(1)	5,443	5,678	5,899
Segi Tiga Atas	AR(0)	5,247	5,633	5,806
	AR(1)	5,470	5,781	5,948

Lampiran 4 Nilai AIC Residual Model GSTARX-GLS ($[1,2]_1$) (*Restricted Model*) Berdasarkan Jenis Bobot Lokasi Pada Data Inflasi Bahan Makanan Tiga Kota di Pulau Papua

Bobot Lokasi	Lag	MA(0)	MA(1)	MA(2)
Invers Jarak	AR(0)	5,243	5,569	5,770
	AR(1)	5,430	5,714	5,892
Normalisasi Korelasi Silang	AR(0)	5,269	5,601	5,804
	AR(1)	5,452	5,792	5,992
Normalisasi Inferensia	AR(0)	5,301	5,634	5,796
Korelasi Silang	AR(1)	5,474	5,803	5,942
Konektivitas	AR(0)	5,301	5,634	5,796
	AR(1)	5,474	5,803	5,942
Segi Tiga Atas	AR(0)	5,360	5,693	5,839
	AR(1)	5,546	5,910	6,023

Lampiran 5 Proc ARIMA Univariate Inflasi Bahan Makanan di Kota Jayapura

```
data test1;
input Y1 Y2      Y3_1 ;
datalines;
      6.59      7.28      1.34907
      6.06      5.02      0.68557
      ...      ...      ...
      0.18     -0.79      3.38526
     -2.06      0.23      2.61151
     -0.52      0.09      3.98121
;

proc arima data=test1;
/*--- Pemodelan ARIMA Y1 JAYAPURA -----*/
identify var=Y1 nlag=24 noprint;
run;

estimate q=(9) method=cls plot;
run;
forecast out=ramalan ;
run;
/*-----mengecek asumsi normalitas residual-----*/
proc univariate data=ramalan normal plot;
var residual;
run;
proc export data=work.ramalan
/*-----memindahkan file-----*/
outfile='D:\ARIMA\NoDiff_Y1.xls'
dbms=excel replace;
sheet="AR(9)";
run;
```

Lampiran 6 Output SAS Model ARIMA ([9],0,0) Kota Jayapura

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	0.65419	0.26994	2.42	0.0176	0
AR1,1	-0.30507	0.11883	-2.57	0.0121	9

Constant Estimate	0.853762
Variance Estimate	9.962003
Std Error Estimate	3.156264
AIC	433.4548
SBC	438.3165
Number of Residuals	84

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.90	5	0.2279	-0.201	0.080	-0.114	-0.134	-0.015	-0.002
12	9.50	11	0.5761	-0.050	-0.092	-0.035	0.031	0.039	0.109
18	15.09	17	0.5893	0.118	-0.021	0.082	-0.129	0.057	-0.109
24	21.40	23	0.5565	-0.101	-0.082	0.030	-0.015	0.190	-0.012

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.986851	Pr < W	0.5546
Kolmogorov-Smirnov	D	0.068898	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.063805	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.409371	Pr > A-Sq	>0.2500

Lampiran 7 Output SAS Model ARIMA ([2,6],0,0) Kota Manokwari

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	0.78793	0.29653	2.66	0.0095	0
MA1,1	0.29169	0.10428	2.80	0.0064	2
MA1,2	-0.24561	0.10690	-2.30	0.0242	6

Constant Estimate	0.787931
Variance Estimate	8.316085
Std Error Estimate	2.883762
AIC	419.2549
SBC	426.5473
Number of Residuals	84

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.85	4	0.7641	-0.078	0.028	-0.012	-0.074	0.078	0.044
12	10.96	10	0.3605	0.177	-0.032	-0.168	0.018	-0.050	0.175
18	13.60	16	0.6286	-0.098	-0.028	-0.109	-0.032	0.043	0.016
24	20.92	22	0.5256	0.104	-0.115	-0.078	0.011	0.048	0.174

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.977012	Pr < W	0.1378
Kolmogorov-Smirnov	D	0.08012	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.119713	Pr > W-Sq	0.0627
Anderson-Darling	A-Sq	0.698926	Pr > A-Sq	0.0693

Lampiran 8 Output SAS Model ARIMA (1,0,0) Kota Sorong dengan Deteksi Outlier

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MU	2.51947	0.08304	30.34	<.0001	0
MA1,1	-0.32356	0.10462	-3.09	0.0027	1

Constant Estimate	2.51947
Variance Estimate	0.332912
Std Error Estimate	0.576985
AIC	147.9678
SBC	152.8294
Number of Residuals	84

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.68	5	0.1224	0.025	0.005	-0.218	-0.034	-0.208	-0.060
12	12.37	11	0.3368	-0.033	-0.080	0.043	-0.016	0.020	0.165
18	18.44	17	0.3616	0.089	-0.007	-0.146	0.014	-0.136	-0.096
24	22.86	23	0.4690	0.093	0.052	-0.045	-0.096	0.103	0.070

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.96317	Pr < W 0.0168
Kolmogorov-Smirnov	D 0.104468	Pr > D 0.0229
Cramer-von Mises	W-Sq 0.177467	Pr > W-Sq 0.0099
Anderson-Darling	A-Sq 1.129256	Pr > A-Sq 0.0058

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MU	2.51854	0.07875	31.98	<.0001	0	Y3_2	0
MA1,1	-0.39896	0.10757	-3.71	0.0004	1	Y3_2	0
NUM1	-1.77560	0.49053	-3.62	0.0005	0	a2	0
NUM2	1.44279	0.48106	3.00	0.0036	0	a68	0

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.52	5	0.4773	0.037	0.038	-0.134	-0.025	-0.136	-0.100
12	11.80	11	0.3787	0.056	-0.226	0.055	0.027	-0.012	0.132
18	19.12	17	0.3216	0.108	-0.014	-0.154	-0.006	-0.078	-0.165
24	24.61	23	0.3710	0.090	0.064	-0.053	-0.086	0.114	0.108

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.969618	Pr < W	0.0443
Kolmogorov-Smirnov	D	0.093132	Pr > D	0.0722
Cramer-von Mises	W-Sq	0.12305	Pr > W-Sq	0.0550
Anderson-Darling	A-Sq	0.840686	Pr > A-Sq	0.0301

Lampiran 9 Output SAS Model Fungsi Transfer (2,0,0) Kota Jayapura

The ARIMA Procedure

Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MU	3.40143	1.10276	3.08	0.0020	0	Y1	0
AR1,1	-0.33379	0.11195	-2.98	0.0029	1	Y1	0
NUM1	-2.29925	0.85130	-2.70	0.0069	0	Y1W2	2

Constant Estimate	4.536777
Variance Estimate	8.762112
Std Error Estimate	2.960086
AIC	413.7436
SBC	420.9638
Number of Residuals	82

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.13	5	0.4001	-0.010	-0.033	-0.109	-0.201	0.015	0.067
12	17.94	11	0.0829	-0.024	-0.144	-0.231	0.089	0.155	0.167
18	22.27	17	0.1744	0.113	-0.115	0.020	-0.102	0.033	-0.065
24	32.52	23	0.0899	-0.157	-0.156	-0.009	-0.022	0.170	0.108

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.983787	Pr < W	0.3901
Kolmogorov-Smirnov	D	0.061293	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.045909	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.333448	Pr > A-Sq	>0.2500

Lampiran 10 Output SAS Model Fungsi Transfer (6,0,0) Kota Manokwari

The ARIMA Procedure

Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.56576	0.25886	2.19	0.0288	0	Y2W2	6

Variance Estimate 8.947432
 Std Error Estimate 2.991226
 AIC 393.2745
 SBC 395.6312
 Number of Residuals 78

Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	10.77	6	0.0958	-0.087	-0.228	-0.047	-0.117	-0.051	0.223
12	18.62	12	0.0981	0.137	-0.091	-0.168	0.031	-0.019	0.173
18	23.69	18	0.1655	0.036	-0.103	-0.158	0.026	0.066	0.095
24	36.06	24	0.0541	0.117	-0.119	-0.132	-0.075	0.107	0.219

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.965373	Pr < W	0.0322
Kolmogorov-Smirnov	D	0.095145	Pr > D	0.0806
Cramer-von Mises	W-Sq	0.113273	Pr > W-Sq	0.0773
Anderson-Darling	A-Sq	0.704622	Pr > A-Sq	0.0667

Lampiran 11 Output SAS Model Fungsi Transfer (0,[2],0) Kota Sorong

The ARIMA Procedure

Maximum Likelihood Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MU	2.69568	0.30597	8.81	<.0001	0	Y3	0
NUM1	0.36407	0.13831	2.63	0.0085	0	Y3W2	0
NUM1,1	0.45075	0.13916	3.24	0.0012	2	Y3W2	0

Constant Estimate	2.695684
Variance Estimate	0.267823
Std Error Estimate	0.517516
AIC	127.6204
SBC	134.8405
Number of Residuals	82

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.91	6	0.0640	0.269	0.031	0.051	0.159	-0.098	-0.161
12	15.27	12	0.2272	-0.108	-0.097	0.006	-0.046	-0.047	0.100
18	22.95	18	0.1926	0.019	-0.132	-0.105	0.064	-0.102	-0.173
24	26.21	24	0.3427	-0.027	0.084	0.041	-0.049	0.067	0.109

Tests for Normality

Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.972841	Pr < W	0.0791
Kolmogorov-Smirnov	D	0.078389	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.10445	Pr > W-Sq	0.0975
Anderson-Darling	A-Sq	0.768928	Pr > A-Sq	0.0450

Lampiran 12 Output Uji Mc-Leod Li (1981) pada Residual Model ARIMA IBM di Pulau Papua

Lag k	Model ARIMA					
	Jayapura		Manokwari		Sorong	
	Q(k)	p_value	Q(k)	p_value	Q(k)	p_value
(1)	(2)	(3)	(4)	(5)	(6)	(7)
1	0.11	0.736	0.19	0.662	0.43	0.510
2	0.24	0.889	0.20	0.906	4.76	0.092
3	0.72	0.868	0.70	0.873	5.89	0.117
4	1.45	0.836	1.55	0.817	6.86	0.143
5	3.70	0.593	1.72	0.886	9.66	0.085
6	4.06	0.668	2.83	0.830	10.08	0.121
7	4.25	0.751	3.41	0.844	10.62	0.156
8	4.95	0.763	3.48	0.901	11.07	0.198
9	4.99	0.836	3.66	0.933	11.99	0.214
10	5.31	0.869	3.76	0.958	12.19	0.273
11	5.98	0.874	3.88	0.973	12.46	0.330
12	6.04	0.914	4.80	0.964	12.46	0.410
13	6.60	0.922	5.76	0.954	13.75	0.392
14	6.78	0.943	5.96	0.967	13.91	0.457
15	8.20	0.916	6.93	0.959	15.47	0.418
16	8.20	0.943	8.70	0.925	15.51	0.488
17	9.03	0.939	8.71	0.949	15.64	0.549
18	9.33	0.952	9.16	0.956	15.68	0.615
19	10.42	0.942	9.18	0.970	15.88	0.665
20	11.39	0.935	10.05	0.967	16.18	0.705
21	13.59	0.887	15.60	0.791	16.22	0.757
22	13.60	0.915	16.84	0.772	16.88	0.770
23	13.74	0.934	17.05	0.807	17.08	0.805
24	13.77	0.952	17.38	0.832	17.18	0.841

Lampiran 13 Output Uji Mc-Leod Li (1981) pada Residual Model Fungsi Transfer IBM di Pulau Papua

Lag k	Model Fungsi Transfer					
	Jayapura		Manokwari		Sorong	
	$Q(k)$	p_value	$Q(k)$	p_value	$Q(k)$	p_value
(1)	(2)	(3)	(4)	(5)	(6)	(7)
1	0.31	0.580	0.00	0.996	1.11	0.292
2	0.41	0.816	0.30	0.859	1.27	0.530
3	0.76	0.858	0.73	0.867	1.43	0.699
4	1.41	0.843	2.36	0.671	1.98	0.739
5	1.94	0.858	2.37	0.795	1.99	0.850
6	2.21	0.900	3.01	0.808	2.56	0.862
7	2.47	0.929	3.17	0.868	2.89	0.895
8	2.59	0.957	3.24	0.919	3.28	0.915
9	2.69	0.975	3.48	0.942	3.49	0.942
10	3.19	0.977	3.62	0.963	3.68	0.961
11	6.50	0.838	3.67	0.979	3.88	0.973
12	6.50	0.889	3.90	0.985	4.16	0.980
13	6.60	0.921	5.06	0.974	7.41	0.880
14	6.79	0.943	5.44	0.979	7.46	0.916
15	8.06	0.922	5.45	0.988	7.46	0.944
16	8.06	0.947	6.02	0.988	7.57	0.961
17	9.00	0.940	6.09	0.993	7.60	0.974
18	9.01	0.960	6.37	0.994	7.85	0.981
19	9.64	0.961	6.63	0.996	8.48	0.981
20	9.66	0.974	6.72	0.998	8.56	0.987
21	9.78	0.982	10.95	0.964	8.57	0.992
22	12.82	0.938	12.58	0.944	9.48	0.990
23	12.83	0.956	12.65	0.959	9.96	0.992
24	13.39	0.959	12.65	0.972	10.18	0.994

BIOGRAFI PENULIS



Penulis dilahirkan di Kendari pada tanggal 1 Oktober 1986 dan merupakan putri pertama dari tiga bersaudara dari pasangan Bapak Hamiun (Alm) dan Ibu Rasni. Penulis telah menempuh SDN 5 Mandonga (1992-1998), SLTP 9 Kendari (1998-2001) dan SMA 4 Negeri Kendari (2001-2004). Kemudian penulis melanjutkan pendidikan ke jenjang sarjana di Sekolah Tinggi Ilmu Statistik (STIS) Jakarta (2004-2008) jurusan Statistik Ekonomi. Setelah menyelesaikan pendidikan DIV di STIS, penulis ditugaskan bekerja di Kabupaten Manokwari Provinsi Papua Barat. Pada tahun 2015 penulis memperoleh kesempatan untuk mendapatkan beasiswa dari BPS untuk melanjutkan jejang pendidikan S2 di Jurusan Statistika Fakultas MIPA Institut Teknologi Sepuluh Nopember Surabaya. {embaca yang ingin memberikan kritik, saran dan pertanyaan mengenai penelitian ini dapat menghubungi penulis melalui email harniaty@bps.go.id.